

Diseño de Experimentos

Métodos y Aplicaciones

Oscar O. Melo M.
Luis A. López P.
Sandra E. Melo M.



Diseño de Experimentos

Métodos y Aplicaciones

Diseño de Experimentos

Métodos y Aplicaciones

Oscar O. Melo

Luis A. López

Sandra E. Melo



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Bogotá, D. C., Colombia, Junio de 2020

Catalogación en la publicación Universidad Nacional de Colombia

© Universidad Nacional de Colombia
Facultad de Ciencias
© Oscar O. Melo, Luis A. López y Sandra E. Melo

Segunda edición, 2020

ISBN 978-958-794-413-6 (papel)
ISBN 978-958-794-414-3 (digital)

Edición

Coordinación de publicaciones - Facultad de Ciencias
coorpub_fcbog@unal.edu.co

Corrección de estilo:

Juliana Monroy

Diseño de la colección

Leonardo Fernández Suárez

Maqueta $\text{\LaTeX}$

Camilo Cubides

Prohibida la reproducción total o parcial por cualquier
medio sin la autorización escrita del titular de los derechos
patrimoniales

Impreso y hecho en Bogotá, D. C., Colombia

A mis padres Luis Alfredo (en memoria) y Benedicta (en memoria),
mis hijos David y Daniel, mi esposa Clarita y mis hermanos

Luis Alberto

A mis padres María y Gustavo,
mi hijo Juan Andrés, mi esposa Maya y mis hermanos

Oscar

A mis padres María y Gustavo,
mi hijo Selhim Matías y mis hermanos

Sandra

Contenido

Prólogo

xv

Capítulo *uno*

Principios del diseño de experimentos	1
1.1. Introducción	3
1.2. Método científico	3
1.3. Tipos de experimentos	5
1.4. Unidades experimentales y muestrales	8
1.5. Fuentes de variación	9
1.6. Control de la variación del no tratamiento	12
1.7. Propiedades del diseño estadístico	14
1.8. Replicación	17
1.9. Aleatorización	18
1.10. Control local	21
1.11. Clasificación de los diseños	22
1.12. Estrategia de diseño	24
1.12.1. Efecto de diseño de control del error	25
1.12.2. Diseño de tratamientos	25
1.12.3. Diseño de muestreo	27
1.13. Recomendaciones para abordar un estudio experimental	28
1.14. Principio general de inferencia y tipos de análisis estadísticos	32
1.15. Ejercicios	37

Capítulo *dos*

Inferencia sobre dos muestras aleatorias	41
2.1. Introducción	43
2.2. Teoría basada en normalidad	43
2.2.1. Inferencia sobre diferencia de medias poblacionales cuando las varianzas son iguales	44
2.2.2. Inferencia sobre el cociente de varianzas	46

2.2.3. Inferencia sobre diferencia de medias poblacionales cuando las varianzas son desiguales	47
2.3. Efecto de no normalidad	51
2.3.1. Pruebas no paramétricas	52
2.3.2. Estimación robusta	56
2.4. Prueba estadística multivariada para la comparación de dos medias: T^2 -Hotelling	58
2.5. Comparaciones pareadas, estudio de un prueba simultáneo para comparar medias y varianzas	61
2.5.1. Prueba de rangos con signo de Wilcoxon para comparaciones pareadas	63
2.6. Implementación en SAS	64
2.7. Implementación en R	69
2.8. Ejercicios	72

Capítulo tres

Modelos de análisis de varianza	77
3.1. Introducción	79
3.2. Conceptos básicos de modelos lineales	79
3.2.1. Modelo superparametrizado (Modelo S)	79
3.2.2. Modelo de medias de celdas	82
3.3. Estimabilidad	84
3.3.1. Estimadores lineales insesgados (ELIS)	85
3.3.2. Transformaciones lineales y estimabilidad en modelos superparametrizados	90
3.4. Modelos lineales particionados y sumas de cuadrados asociadas	93
3.4.1. Modelo particionado en dos partes	93
3.4.2. Modelo particionado en tres partes	97
3.4.3. Modelo particionado en k partes ordenadas	98
3.5. Sumas de cuadrados y funciones estimables	102
3.5.1. Sumas de cuadrados y funciones estimables tipo I	103
3.5.2. Sumas de cuadrados y funciones estimables tipo II	104
3.5.3. Sumas de cuadrados y funciones estimables tipo III	105
3.5.4. Sumas de cuadrados y funciones estimables tipo IV	106
3.6. Hipótesis más comunes sobre filas y columnas	108
3.7. Implementación en SAS	114
3.8. Implementación en R	118
3.9. Ejercicios	118

Capítulo *cuatro*

Clasificación de modelos en el análisis de varianza y diagramas de estructura	127
4.1. Clasificación de los modelos en el análisis de varianza	129
4.1.1. Supuestos fundamentales	130
4.2. Diagramas de estructuras y análisis de varianza en diseños experimentales	131
4.2.1. Diagramas de estructuras	132
4.2.2. Derivación de fórmulas	135
4.3. Ilustración del procedimiento	141
4.4. Implementación en SAS	148
4.5. Implementación en R	149
4.6. Ejercicios	150

Capítulo *cinco*

Diseños completamente aleatorizados y tamaño de muestra	153
5.1. Diseño completamente aleatorizado	155
5.2. Principios del análisis de varianza	156
5.3. DCA a través del modelo superparametrizado	159
5.3.1. Hipótesis asociadas	163
5.4. DCA a través del modelo de medias de celda	165
5.4.1. Reducción de la suma de cuadrados	167
5.4.2. Hipótesis asociadas	169
5.5. Modelo de componentes de varianza	171
5.6. Análisis de un DCA a través de pruebas de localización no paramétricas	176
5.6.1. Prueba de Kruskal-Wallis	176
5.7. Número de réplicas en un diseño completamente aleatorizado	179
5.7.1. Obtención del tamaño de la muestra a partir de la potencia	182
5.7.2. Método de Harris-Hurvitz-Mood (HHM)	187
5.7.3. Método de Tukey	188
5.7.4. Número de réplicas en el modelo de efectos aleatorios	190
5.7.5. Determinación del tamaño de muestra con costo variable por tratamiento	191
5.8. Submuestreo en diseños completamente aleatorizados	194
5.8.1. Modelo lineal en un DCA con submuestreo	194
5.8.2. Inferencias con submuestreo	195
5.9. Comparación de un DCA sin y con submuestreo	196

5.10. Submuestreo con factores aleatorios	198
5.10.1. Tamaño óptimo de muestra con un costo fijo (Co)	200
5.10.2. Muestra más económica para una precisión dada de estimación	201
5.11. Implementación en SAS	203
5.12. Implementación en R	204
5.13. Ejercicios	211

Capítulo *seis*

Comparaciones múltiples y validación de supuestos	225
6.1. Pruebas de comparaciones múltiples	227
6.1.1. Conceptos preliminares	227
6.1.2. Procedimientos de comparaciones múltiples	228
6.2. Verificación de supuestos	237
6.2.1. Causas de desvíos de supuestos	237
6.2.2. Análisis gráfico y medidas descriptivas de los residuales ..	239
6.2.3. Prueba para detectar anomalías	242
6.2.4. Pruebas para detectar heterocedasticidad	243
6.2.5. Pruebas de normalidad	250
6.2.6. Pruebas de no aditividad	255
6.3. Solución a los problemas de no homocedasticidad... ..	259
6.3.1. Uso de transformaciones	260
6.3.2. Uso de las transformaciones para estabilizar varianza	260
6.3.3. Uso de transformaciones para corregir no normalidad ...	263
6.3.4. Transformación de Box - Cox	265
6.4. Implementación en SAS	266
6.5. Implementación en R	267
6.6. Ejercicios	271

Capítulo *siete*

Diseño de bloques completamente aleatorizados	277
7.1. Introducción	279
7.2. Análisis estadístico	280
7.3. Estimación de una observación faltante	289
7.4. Eficiencia de un DBCA frente a un DCA	292
7.5. Bloques con submuestreo	293
7.5.1. Formas de obtener las sumas de cuadrados	294
7.6. Diseño en bloques incompletos	300

7.6.1. Estructuras matriciales de los bloques incompletos	301
7.7. Análisis de varianza	308
7.8. Diseño en bloques incompletos balanceados	311
7.8.1. Estimación de datos faltantes	317
7.8.2. Método de Scheffé para comparaciones múltiples	318
7.9. Implementación en SAS	319
7.10. Implementación en R	321
7.11. Ejercicios	326

Capítulo ocho

Diseños en cuadro latino y análisis de covarianza	335
8.1. Diseño en cuadro latino	337
8.1.1. Estimación de un dato faltante en un DCL	342
8.1.2. Eficiencia de un DCL frente a un DCA y un DBCA	343
8.2. Series de cuadros latinos	345
8.3. Diseño en Cuadrado Greco-Latino	350
8.4. Análisis de covarianza	353
8.4.1. Análisis de covarianza en un DCA	356
8.4.2. Covariables afectadas por los tratamientos	369
8.4.3. Análisis de covarianza en un DBCA	370
8.4.4. Análisis general de covariables	376
8.5. Implementación en SAS	379
8.6. Implementación en R	382
8.7. Ejercicios	387
8.8. Anexo	393
8.8.1. Campo de Galois	393
8.8.2. Geometrías finitas	395
8.8.3. Cuadros latinos ortogonales	396

Capítulo nueve

Experimentos factoriales	399
9.1. Características generales	401
9.2. Diseño factoriales 2^k	404
9.2.1. Diseño factorial 2^2	405
9.2.2. Diseño factorial 2^3	411
9.2.3. Generalización del diseño factorial 2^k	419
9.3. Experimentos Factoriales 3^k	421
9.3.1. Diseño factorial 3^2	423

9.3.2. Diseño factorial 3^3	435
9.3.3. Generalización del diseño factorial 3^k	443
9.4. Implementación en SAS	445
9.5. Implementación en R	448
9.6. Ejercicios	454
9.7. Anexo	460
9.7.1. Ideas básicas sobre congruencia	460
9.7.2. Breve introducción a conceptos básicos de teoría de grupos	461

Capítulo diez

Confusión en experimentos factoriales	465
10.1. Introducción	467
10.2. Confusión en series 2^k	469
10.2.1. Confusión del diseño factorial 2^k en dos bloques	469
10.2.2. Confusión del diseño factorial 2^k en cuatro bloques	475
10.2.3. Confusión del diseño factorial 2^k en 2^p bloques	477
10.3. Confusión en series 3^k	478
10.3.1. Confusión del diseño factorial 3^k en tres bloques	478
10.3.2. Confusión del diseño factorial 3^k en nueve bloques	481
10.3.3. Confusión del diseño factorial 3^k en 3^s bloques	482
10.4. Confusión en series p^k	483
10.5. Confusión Parcial	483
10.6. Confusión en experimentos factoriales asimétricos	489
10.7. Implementación en SAS	491
10.8. Implementación en R	492
10.9. Ejercicios	494

Capítulo once

Diseños factoriales fraccionados y parcelas divididas	499
11.1. Diseños factoriales fraccionados	501
11.1.1. Fracción un medio del diseño 2^k	502
11.1.2. Resolución de un diseño	505
11.1.3. Fracción un cuarto del diseño 2^k	509
11.1.4. Diseño factorial fraccionado 2^{k-p}	510
11.1.5. Réplicas fraccionadas del diseño factorial 3^k	514
11.2. Diseño en parcelas divididas y subdivididas	518
11.2.1. Análisis estadístico del diseño en parcelas divididas	520

11.2.2. Eficiencia relativa de un diseño de parcelas divididas	524
11.3. Implementación en SAS	526
11.4. Implementación en R	527
11.5. Ejercicios	529

Capítulo *doce*

Metodología de superficies de respuesta	537
12.1. Introducción	539
12.2. Modelo de regresión lineal múltiple	543
12.2.1. Predicción de la variable respuesta y estudios de residuales	545
12.2.2. Resultados para el análisis de varianza	546
12.2.3. Pruebas de hipótesis asociadas a los parámetros indivi- duales en el modelo	548
12.3. Prueba de falta de ajuste	552
12.4. Método de la trayectoria en máximo ascenso	555
12.4.1. Cálculo de la trayectoria en máximo ascenso	556
12.5. Análisis de una superficie de respuesta de segundo orden	560
12.5.1. Localización del punto estacionario	561
12.5.2. Análisis canónico	563
12.6. Análisis de cordillera	569
12.7. Implementación en SAS	572
12.8. Implementación en R	575
12.9. Ejercicios	577

Capítulo *trece*

Diseño experimental con respuesta no normal	581
13.1. Introducción	583
13.2. Familia exponencial	584
13.2.1. Momentos de la familia exponencial	585
13.3. Modelos lineales generalizados	586
13.3.1. Estimación de parámetros en un MLG	588
13.4. Bondad de ajuste de un MLG	590
13.5. MLG con sobredispersión o subdispersión	591
13.5.1. Modelo binomial con sobredispersión o subdispersión . .	592
13.5.2. MLG logit con sobredispersión y subdispersión	592
13.6. Hipótesis sobre el vector de parámetros	594
13.7. Intervalos de confianza de los parámetros y de predicción	594

13.8. Bondad de ajuste y medidas de diagnóstico	595
13.9. Implementación en SAS	601
13.10. Implementación en R.....	604
13.11. Ejercicios	610

Apéndice A

Tablas Estadísticas	615

Bibliografía	657

Índice	669

Prólogo

Esta segunda edición del libro *Diseño de Experimentos: métodos y aplicaciones* la ponemos al servicio de profesores, investigadores y estudiantes de las diferentes áreas del conocimiento científico que dentro de su actividad utilizan métodos experimentales. El libro en esta segunda edición, presenta temas de interés que son relevantes en muchas áreas del conocimiento científico. El libro está escrito en un lenguaje asequible para quienes tengan conocimientos básicos en Métodos Estadísticos y algunos conceptos de Álgebra de Matrices, principios de Modelos Lineales y Modelos Lineales Generalizados. La temática que se aborda, en general puede encontrarse en muchos otros textos especializados en áreas del conocimiento como: Diseños de Experimentos, Modelos Lineales Generalizados y Superficies de Respuesta. Sin embargo, el enfoque teórico práctico que le damos a este texto le da una particularidad especial dentro del marco de los diferentes textos de Diseños de Experimentos que son de amplia circulación en el campo de la estadística experimental. Nuestra motivación fundamental lo constituyen los trabajos de Hinkelmann y Kempthorne (1994, 2005) y Hinkelmann (2012), libros considerados influyentes en el campo de la enseñanza y la investigación de los Diseños Experimentales, estos autores contribuyeron a darnos una visión más amplia de la estadística experimental y a motivarnos a escribir esta obra en lenguaje español.

El libro se divide en trece capítulos, cada uno de ellos además de contener una base teórica entendible, está apoyado por un buen acervo de ejercicios, algunos de ellos orientados en datos reales de ensayos conducidos en la Universidad Nacional de Colombia o en otras instituciones de investigación del país. El capítulo uno titulado principios básicos del diseño de experimentos, es concebido como una herramienta fundamental desde la metodología científica, se hace un recorrido por diferentes conceptos del Diseño Experimental, familiarizando a los lectores con la terminología propia de esta disciplina, así como motivándolos a que continúe con la lectura posterior de los capítulos tratados en este libro. En el capítulo dos se hace una revisión acerca de la comparación de dos muestras aleatorias independientes procedentes de poblaciones donde se puede o no conocer la distribución de dónde proceden

los datos, se presentan los resultados de Bradley y Blackwood (1989), para la comparación simultánea de medias y varianzas en poblaciones normales. Por su importancia en la teoría de los diseños experimentales, se presenta en el capítulo tres una revisión de los Modelos Lineales de Gauss-Markov, enfatizando en los modelos de rango incompleto con estructura desbalanceada de datos, caracterizando en forma sencilla las diferentes sumas de cuadrados asociadas a las hipótesis lineales que sean estimables, de acuerdo a la identificación de la base de funciones estimables y combinaciones lineales de estas.

En el capítulo cuatro se presenta un desarrollo aplicado sobre diagramas de estructuras de gran importancia en la identificación y caracterización de los experimentos con efectos fijos o aleatorios utilizando en factores cruzados o anidados. A partir del capítulo cinco se presentan los diferentes tipos de diseños teniendo en cuenta el concepto de control del error experimental, iniciando con el diseño sin restricción en la aleatorización, entendiendo este como la forma más simple de concebir los diseños; se busca en este capítulo, divulgar los métodos paramétricos y no paramétricos en el estudio de tratamientos con efectos fijos y aleatorios así como la determinación de los tamaños óptimos de muestra en diseños completamente aleatorizados (DCA) y DCA con submuestro.

En el capítulo seis se hace una revisión de los métodos de comparaciones planeadas y no planeadas bajo normalidad, presentando adicionalmente diferentes estrategias y procedimientos para la verificación de supuestos, en el caso de información procedente de poblaciones normales. Por su importancia en la investigación experimental se presenta en el capítulo siete los diseños en bloques completamente aleatorizados (DBCA) con estructura balanceada y desbalanceada, enfatizando en los bloques completos; aunque se hace un estudio de los bloques incompletos, sin embargo, este tema puede ser ampliando en los libros de Hinkelman y Kempthorne (1994, 2005). En el capítulo ocho se lleva a cabo el estudio de los diseños con doble control local en la aleatorización, enfatizando en los diseños de cuadros latinos (DCL) completos e incompletos y en forma general se desarrollan los cuadrados grecolatinos y, se extiende el concepto a diseños en series de cuadros latinos ortogonales. Adicionalmente, se hace una revisión general del *análisis de covarianza* como método para reducir el error experimental; se enfatiza en el estudio de una covariable cuando los ensayos experimentales se conducen en DCA, DBCA, y DCL y, se presenta una extensión cuando se tiene más de una covariable en los ensayos experimentales.

En los capítulos nueve, diez y once se aborda el estudio de los diseños experimentales con arreglos factoriales, introduciendo la noción de


diseños de tratamientos simétricos y asimétricos; enfatizando en los principios de confusión parcial y total con dos y tres niveles de clasificación, se estudian con rigor los diseños factoriales fraccionados, teniendo en cuenta las fracciones regulares e irregulares y al final del capítulo once, se estudian los diseños en parcelas divididas y subdivididas, las cuales tienen gran relevancia en investigación agropecuaria e investigación industrial. Seguidamente, en el capítulo doce se lleva a cabo una introducción a la metodología de superficies de respuesta, con modelos de primer y segundo orden. Estos métodos de optimización solo tienen en cuenta datos procedentes de distribuciones normales.

Finalmente, en el capítulo trece se lleva a cabo una introducción a los diseños experimentales con respuesta no normal dentro del marco de la familia exponencial, los cuales tienen como soporte la teoría de los modelos lineales generalizados (MLG). Se enfatiza únicamente en los experimentos donde la respuesta son conteos, por lo tanto se aborda el análisis con respuesta utilizando experimentos como Poisson para conteos, Binomial para datos con respuesta binaria y de proporciones discretas, Gamma para datos donde los experimentos buscan evaluar los tiempos de falla y otras distribuciones que de acuerdo al tipo de respuesta experimental forman parte de la Familia Exponencial. Se resalta que en este tipo de ensayos experimentales, sucede con frecuencia que el supuesto de varianza constante no se satisface y, además, es una función de la media, contrario a lo que sucede con datos bajo distribución normal en los que el uso de métodos de estimación como el de mínimos cuadrados proporciona estimadores con mínima varianza.

El libro tiene al final de cada capítulo, la implementación de algunas de las aplicaciones con SAS y el software libre R (R Development Core Team 2020). La programación en R se presenta como un aporte adicional en esta segunda edición. Por el nivel presentado en este texto, puede servir de apoyo a los estudiantes de pregrado y especialización en estadística en su primer curso de la asignatura Diseño de Experimentos. Sin embargo, algunos capítulos pueden ser útiles a los estudiantes de maestría y doctorado en estadística. Varios de los capítulos del libro también se han venido enseñando en la Facultad de Ciencias Agrarias a través del curso ofertado como diseño de experimentos tanto a estudiantes de pregrado como posgrado, en esté último hemos contado con estudiantes de diferentes maestrías y doctorados de la Universidad Nacional de Colombia durante los últimos años. Este es un texto con un lenguaje que puede ser consultado por investigadores de otras áreas del conocimiento que hagan uso de técnicas experimentales, con la facilidad de encontrar la programación en R y SAS para realizar los diferentes análisis de los diseños experimentales abordados a lo largo del texto.

Queremos expresar los más sinceros agradecimientos a nuestros estudiantes del departamento de Estadística y de la facultad de Ciencias Agrarias de la Universidad Nacional de Colombia, sede Bogotá. A los estudiantes de pregrado y posgrado del departamento de Estadística que a lo largo de los últimos veinte años colaboraron con la revisión permanente de los borradores y la primera edición del libro, presentaron sugerencias y recomendaciones, las cuales contribuyeron ampliamente a mejorar el manuscrito. Igualmente a los estudiantes de pregrado y posgrado de la facultad de Ciencias Agrarias, quienes en los cursos durante los últimos trece años, han contribuido con sus comentarios y propuestas que han logrado enriquecer el texto. Agradecemos a la oficina de publicaciones de la Facultad de Ciencias. Agradecemos al Departamento de Estadística por el constante apoyo que siempre nos ha dado para que este libro tuviera el final que estamos poniendo a su consideración. Nuestro agradecimiento especial a la estudiante de Maestría en Estadística Patricia Chávez, quien siempre estuvo atenta a apoyarnos en las correcciones y en la transcripción de nuestro manuscrito; su apoyo fue fundamental en la finalización de este libro.

Este trabajo hace parte de la contribución académica del grupo de investigación en Estadística Aplicada a la Investigación Experimental, Industria y Biotecnología. Los errores e imperfecciones, compañeros inseparables de los textos escritos, son de la exclusiva responsabilidad de los autores.



Capítulo

uno

Principios del diseño de experimentos

1.1. Introducción

Diseñar estadísticamente un experimento es realizar una prueba o una serie de pruebas buscando caracterizar las variables explicativas o factores (X_i) de mayor influencia en un ensayo de interés, evaluado a través de una o varias variables respuesta(s), tal que si deliberada o sistemáticamente se introducen cambios controlados en algunas de las variables explicativas del proceso, siempre sea posible observar o cuantificar los cambios que estos generan en la(s) variable(s) respuesta(s). Adicionalmente, se busca minimizar el efecto de las variables no controlables (covariables), procurando con ello estabilizar y minimizar la variabilidad de las respuestas, identificando los factores que contribuyen a las mayores causas de variabilidad.

Aunque la aplicación o uso del diseño experimental se da en la mayoría de las áreas del conocimiento, este debe cumplir las siguientes fases:

1. *Caracterización de un proceso:* en esta fase se busca determinar los rangos de las variables o factores controlables de mayor influencia en la(s) variable(s) respuesta(s), que a la vez minimizan el efecto de las variables no controlables (factores o covariables).
2. *Depuración y optimización de un proceso ya caracterizado:* en esta fase se hallan los niveles de los factores estudiados que proporcionan la respuesta óptima a la solución del proceso caracterizado en la fase anterior.

En cualquier aplicación de la estadística, en el marco del diseño y análisis de un experimento, es necesario que quienes lo desarrollen entiendan claramente el problema objeto de estudio, posean un amplio conocimiento del material experimental a usar, conozcan las posibilidades existentes para coleccionar los datos y, además, tengan el conocimiento estadístico necesario para direccionar e interpretar adecuadamente los resultados del experimento. Generalmente, el grupo de investigación debe estar conformado por expertos conocedores de la problemática a estudiar (biólogos, agrónomos, ingenieros, etc.), y especialistas en la plantación del diseño estadístico y el análisis apropiado de la información recolectada.

1.2. Método científico

El método científico ha sido definido como una aplicación de la lógica y la objetividad para el entendimiento de los fenómenos naturales y sociales.

Para este fin, es esencial el estudio de lo que ya se conoce, pues es a partir de este conocimiento que se formulan las hipótesis, las cuales se ponen a prueba partiendo, por lo general, de situaciones experimentales planeadas; siendo esta la parte crucial de todo el proceso, ya que cualquier pregunta en que las respuestas no puedan obtenerse a partir de la investigación no puede aceptarse como parte del método científico.

El método científico no es estático, es de naturaleza circulante. De acuerdo con Kempthorne (1952), la primera etapa es la observación del fenómeno en estudio, durante la cual se colectan los elementos básicos, en términos abstractos, a partir de los cuales se establecen las bases lógicas de una teoría, siendo esta la segunda etapa del método. En la tercera etapa, se lleva a cabo el desarrollo propiamente dicho de esta teoría, de tal forma que, en la cuarta etapa, se puede llegar a la predicción de eventos futuros para tomar decisiones sobre un factor y/o tratamiento. Una vez se termina este ciclo, el proceso vuelve a repetirse de acuerdo con la decisión sobre las hipótesis planeadas, consolidando los fundamentos teóricos, buscando así una mayor precisión en la etapa de la predicción.

En este sentido, la estadística juega un papel importante en la fundamentación del método científico, mediante tres funciones primordiales que son: la descripción, el análisis y la predicción.

En la investigación científica es común la formulación de la hipótesis, la cual, para su aceptación o rechazo, debe estar sustentada por un conjunto de observaciones a seleccionarse a través de un patrón bien definido. Este patrón se conoce como *diseño experimental*.

Se deben destacar dos aspectos esenciales en el método científico:

- i. Examen crítico de resultados experimentales previos basados en el conocimiento corriente, con el fin de formular nuevas hipótesis para ser *juzgadas* por medio de la experimentación.
- ii. Diseño de experimentos recomendados para el estudio experimental del problema, con el propósito de proveer mayor información de posibles soluciones.

Estos dos aspectos implican una naturaleza interactiva para la experimentación práctica. Box (1957) estableció cuatro etapas básicas. Estas son:

1. Conjeturas, donde las investigaciones experimentales de resultados iniciales son tenidas en cuenta para plantear nuevas hipótesis a ser *juzgadas*.
2. Diseño y planeación del experimento, donde algunas formas para juzgar una nueva hipótesis son desarrolladas.

3. Desarrollo del experimento.
4. Análisis, donde los datos experimentales son cuidadosamente examinados para determinar qué evidencia tienen en relación con la hipótesis de estudio.

Una vez se ha alcanzado la última etapa, el ciclo comienza nuevamente con la formulación de nuevas hipótesis. De esta manera, conceptos originales son modificados y un mejor entendimiento del problema y sus posibles soluciones lentamente va evolucionando. Las principales contribuciones estadísticas a este proceso iterativo ocurren en el diseño de experimentos y en el análisis de los datos.

El propósito del análisis es proveer una explicación razonable a la evidencia experimental para determinar cuáles hipótesis están en contradicción con la evidencia, proveer estimaciones de parámetros poblacionales, indicar el nivel de confianza que puede asignarse a cualquier conclusión alcanzada y estimular el proceso de conjeturas por parte del experimentador. Esto no podrá ser realizado a menos que un diseño de experimentos válido haya sido usado. Por tanto, es una función del diseño experimental proveer los patrones de observación a ser recolectados, con el fin de obtener estimaciones precisas y/o tener la capacidad de probar las distintas hipótesis (sobre efectos de medias o combinaciones lineales de medias y sobre efectos de varianzas) con una potencia de discriminación máxima.

1.3. Tipos de experimentos

Anscombe (1947) clasificó los experimentos como pertenecientes a dos tipos. El primero es *el experimento absoluto* en el cual el interés principal es la estimación y la determinación de las propiedades físicas de la población a ser estudiada. Se espera que estas propiedades sean constantes, de allí el término *absoluto*. El propósito del experimento absoluto es incrementar el conocimiento científico. En estos experimentos un factor singular es estudiado frecuentemente para examinar un número reducido de tratamientos posibles o niveles de un factor. La selección de los tratamientos se hace generalmente mediante *procesos aleatorios*. Por tanto, si el experimento puede ser repetido, el mismo grupo de tratamientos no necesariamente será utilizado. Por esta razón, el tratamiento es considerado una variable aleatoria y el modelo señalado es un *modelo de efectos aleatorios* o Modelo II de Eisenhart (1947), bajo el cual se detectan y estiman componentes (aleatorias) de variación asociada a una población compuesta.

El segundo tipo es *el experimento comparativo*. Frecuentemente cuando se estudia un grupo de tratamientos, los resultados absolutos varían erráticamente mientras que los resultados relativos permanecen razonablemente estables. En estas situaciones es posible establecer que, en circunstancias similares, se espera que ciertos tratamientos sean sustancialmente “mejores” que otros, aunque los resultados de un solo tratamiento no pueden ser establecidos con exactitud. En estos campos de la experimentación, los experimentos tienden a ser comparativos y tienen un interés secundario dado por los resultados absolutos. Brownlee (1957), clasifica estos experimentos como ciencias aplicadas. La teoría estadística del diseño de experimentos se relaciona inicialmente con este tipo de experimentos.

En la segunda clasificación de los experimentos los tratamientos se comparan por sus efectos medios sobre una variable respuesta con el objeto principal de determinar cuál de ellos es “mejor” en algún sentido. El propósito de este experimento es proveer información necesaria para tomar decisiones administrativas satisfactorias acerca del objetivo planteado. La principal característica de este tipo de experimentación es que todos los tratamientos de interés están incluidos en el ensayo. Consecuentemente, la estructura matemática básica es el modelo de efectos fijos, modelo I de Eisenhart (1947), ya que bajo experimentos repetidos se seleccionarán los mismos tratamientos. En este caso, es de interés la detección y estimación de relaciones determinadas (constantes) entre las medias del universo de objetos considerados. Para estos modelos, *el interés primordial es juzgar varias hipótesis relacionadas con las medias de los tratamientos*.

El experimento comparativo comienza con un planteamiento exacto del problema a ser resuelto. Esto es, se debe hacer una especificación detallada de los objetivos del experimento con una formulación precisa de la hipótesis a juzgar. Es insuficiente solamente establecer en forma simple la idea de “*comparar estos tratamientos*”. Esta especificación define la población a la cual las conclusiones serán aplicadas, determina los factores, tratamientos y sus niveles, especifica las variables respuesta a ser medidas y establece las diferencias críticas a ser detectadas. *Sin estas especificaciones, ningún experimento podrá ser diseñado adecuadamente*.

Una consecuencia general de los experimentos comparativos es que pueden conducir a decisiones administrativas sobre los objetivos planteados. Como es de esperarse, la hipótesis nula para igualdad de efectos medios de los tratamientos siempre será rechazada dados determinados recursos. En consecuencia, algunas acciones deberán tomarse siempre sobre la base de los resultados obtenidos; bien sea manteniendo todo tal cual o cambiando por un nuevo tratamiento. Estas decisiones son un proceso de dos etapas:

1. Examen (análisis) de las probabilidades asociadas a las estimaciones a partir de los datos con las conclusiones (acción estadística).
2. Basados en estos resultados, se toma la decisión para implementar una acción (decisión de gestión).

El trabajo del estadístico es presentar las probabilidades de la primera etapa lo más acertadamente posible para minimizar el número de decisiones incorrectas a tomar en la segunda etapa.

Como lo fundamental en la decisión sobre las hipótesis son los experimentos planeados, es necesario que se tengan en cuenta las siguientes características generales para estos ensayos:

- i. *Simplicidad*: se debe tener en cuenta que tanto la selección de los tratamientos como la disposición experimental deberá hacerse de la forma más simple posible.
- ii. *Grado de precisión*: el experimento deberá tener la capacidad de medir diferencias entre tratamientos con los grados de precisión que desee el investigador. Para cumplir con este propósito se deberá tener entonces un diseño apropiado y un número de repeticiones adecuado.
- iii. *Ausencia de error sistemático*: se debe planear un experimento con el propósito de asegurar que las unidades experimentales que reciban un tratamiento no difieran sistemáticamente de aquellas que reciben otro, procurando de esta manera obtener una estimación insesgada del efecto de tratamiento.
- iv. *Rango de validez de las conclusiones*: las conclusiones deberán tener un rango de validez tan amplio como sea posible. Los experimentos que contribuyen a aumentar este rango son los experimentos replicados y los experimentos con estructuras factoriales.
- v. *Cálculo del grado de incertidumbre*: en todo experimento existe algún grado de incertidumbre en cuanto a la validación de las conclusiones. El experimento deberá ser concebido de modo que sea posible calcular la probabilidad de obtener los resultados observados debido únicamente a la aleatoriedad.

Los anteriores conceptos conducen a la siguiente definición (Eisenhart 1947).

Definición 1.1. Cuando al finalizar el experimento las conclusiones se formulan sobre un número pre-establecido de tratamientos, el modelo se llama

modelo de efectos fijos y, en este caso, la inferencia se hace sobre los efectos medios de los tratamientos. Si los tratamientos del experimento son una muestra aleatoria de una población de tratamientos, las conclusiones se formulan sobre un número mayor de tratamientos a los usados en el experimento, el modelo se llama *modelo de efectos aleatorios* y, en este caso, la inferencia se hace sobre las varianzas de los tratamientos. Si en la conducción del experimento se combinan los modelos anteriores, el modelo se denomina *modelo de efectos mixtos* y la inferencia se hace en forma simultánea sobre las medias y las varianzas.

Ejemplo 1.1. *En un problema de inseminación artificial para seleccionar reproductores de una raza específica, los machos pueden tener descendencia en diferentes hatos. Si la variable de interés para la selección es la producción de leche de las hembras cruzadas y los machos son tomados como una muestra de la raza en cuestión, el modelo es de efectos aleatorios y la inferencia se hace para seleccionar los mejores machos en el experimento, teniendo como soporte la producción de leche de las hembras. Si se fija un número determinado de razas sobre el cual se selecciona aleatoriamente un número determinado de machos, el modelo es de efectos mixtos y en la parte del diseño la inferencia se hace sobre los mejores tratamientos (parte aleatoria) y la mejor raza (parte fija).*

1.4. Unidades experimentales y muestrales

El elemento básico en los experimentos comparativos es la unidad experimental (UE). Este concepto se usará en la siguiente definición.

Definición 1.2. Los elementos sobre los cuales se hacen las mediciones y a los cuales un tratamiento puede ser asignado aleatoriamente e independientemente se denomina *unidad experimental* (UE), y el conjunto de unidades experimentales se denomina *material experimental*. Cada UE contiene una o más *unidades muestrales u observacionales* (UO) en las cuales las condiciones experimentales planeadas previamente se realizan.

Ejemplo 1.2.

- a) *En un experimento agrícola para evaluar el rendimiento de algunas variedades de maíz, la UE puede ser una porción de terreno de tamaño óptimo preestablecido, usualmente denominada parcela, o un número de plantas o un número de mazorcas.*
- b) *En un estudio clínico, un paciente sometido a un tratamiento terapéutico puede ser considerado como una UE.*

- c) *En un trabajo en entomología, la UE puede ser un insecto, una colonia o toda una especie. En general, la definición de la UE depende de los objetivos de la investigación y de los recursos disponibles.*

Por definición, las unidades experimentales deben estar en capacidad de recibir cualquiera de los tratamientos que estén bajo investigación, de acuerdo con el objeto de estudio.

Definición 1.3. En la conducción del experimento existen dos grupos de variables: las *variables respuestas* que proporcionan las mediciones del experimento, las cuales varían debido a la diversidad presente entre las unidades experimentales, y las *variables explicativas* que influyen en las respuestas, denominadas *factores*; entre estos existen los denominados factores de clasificación que, según sus valores, definen los niveles de clasificación sobre los cuales se hace la inferencia.

Observación 1.1. Por su naturaleza, las unidades muestrales de la misma UE deben recibir el mismo tratamiento. Consecuentemente, la asignación del tratamiento a estas unidades muestrales no es independiente.

Esta distinción es importante, dado que para hacer inferencia sobre los efectos de los tratamientos se requiere tener un conocimiento de la estimación de la variabilidad inherente al material experimental, la cual es conocida como el *error experimental*. Esta estimación es dada por la variación entre unidades idénticamente tratadas, las cuales inicialmente pudieron ser tratadas de forma diferente (según la aleatorización propuesta). La variación entre las unidades experimentales provee una estimación del error experimental y, adicionalmente, esta variación entre unidades muestrales dentro de las unidades experimentales es un valor muy pequeño al calcular los errores de estimación de los efectos del tratamiento y provee una estimación del error de muestreo.

1.5. Fuentes de variación

Los tratamientos se asignan a las unidades experimentales para determinar si tienen un efecto sobre la respuesta de interés. Cualquier efecto podrá resultar en diferencias sistemáticas de respuesta entre unidades experimentales. Para detectar estas diferencias, las unidades experimentales deberán ser lo más homogéneas posibles, es decir, la variación entre unidades experimentales uniformemente tratadas debe ser menor en relación con las diferencias entre tratamientos. Si esto no ocurre, la variación de las unidades experimentales

pueden resultar en un “fracaso” para encontrar diferencias de tratamientos, los cuales son importantes en la investigación.

Desafortunadamente, las unidades experimentales en general no serán homogéneas porque ellas poseen diferentes propiedades físicas inherentes para una o más características. Frecuentemente detrás del control del experimentador, estos factores inherentes causan diferencias sistemáticas entre las unidades experimentales creando fuentes de variación no deseadas. Estas fuentes son de escaso interés práctico y no están relacionadas con el estudio. Por esta razón, se conocen como “*fuentes extrañas de variación*”. No es necesariamente cierto que todas estas fuentes de variación sean conocidas por el experimentador. Se sabe que estos factores pueden ser usados para clasificar las unidades experimentales en subgrupos más homogéneos.

Mientras el error experimental es una variación aleatoria, no toda variación aleatoria es error experimental.

La variación entre unidades muestrales dentro de las unidades experimentales es también una variación aleatoria, pero no debe dársele mucho valor al juzgar los efectos de los tratamientos. Los tratamientos son parte de la estructura de la UE y hay una diferencia básica *entre la clasificación y los factores de tratamiento*; los factores de clasificación son propiedades inherentes a la UE y solo (raramente) pueden ser cambiados por el experimentador.

Definición 1.4. Cada combinación específica de niveles de factores se denomina *tratamiento*.

Ejemplo 1.3. Se planea un experimento para evaluar el rendimiento de maíz en función del tipo de variedad V_1, V_2, V_3 y los nutrientes N y P a los niveles (10, 30) y (20, 40), respectivamente. Los posibles 12 tratamientos (V, N, P) son:

$(V_1, 10, 20)$	$(V_2, 10, 20)$	$(V_3, 10, 20)$
$(V_1, 30, 20)$	$(V_2, 30, 20)$	$(V_3, 30, 20)$
$(V_1, 10, 40)$	$(V_2, 10, 40)$	$(V_3, 10, 40)$
$(V_1, 30, 40)$	$(V_2, 30, 40)$	$(V_3, 30, 40)$

El concepto de tratamiento implica que:

1. Cualquier UE está en capacidad de recibir cualquier tratamiento.
2. La asignación de tratamientos a la UE está bajo el control del experimentador.

Bajo esta definición, en un experimento que compare medicamentos, por ejemplo, el género *nunca* podrá ser considerado como un factor (tratamiento). El género de un sujeto particular es una propiedad intrínseca del sujeto que

no podrá ser asignado al experimentador. Sin embargo, los medicamentos constituyen un tratamiento, ya que a cada sujeto incluido en el estudio (UE) se le puede asignar un medicamento.

La distinción entre tratamiento y factores de clasificación no es absoluta. Martin (1989) cita un ejemplo propuesto por Box, en el cual se desean comparar tratamientos retardadores del fuego. Estos tratamientos serán aplicados a muestras de madera con superficies ásperas o suaves. La superficie de madera no representa un factor de tratamiento a menos que el experimentador pueda especificar los tipos de superficies de las piezas. Así, si el experimentador tiene una oferta de pedazos ásperos de madera y puede decidir cuáles son suaves, entonces el tipo de superficie será un factor de tratamiento. Si el tipo de superficie es una propiedad intrínseca de las especies maderables elegidas, entonces será un factor de clasificación.

Como afirman Cochran y Cox (1957), los tratamientos deben tener las siguientes particularidades:

1. Presentar la finalidad, es decir, si pretende simplemente “mostrar el ganador” entre los diferentes tratamientos o si además se desean encontrar indicios acerca del comportamiento de los tratamientos. Un caso particular es el ensayo con un fertilizante compuesto por dos sustancias A y B principalmente. El resultado no muestra si la efectividad del fertilizante se debe a alguno de los dos componentes o a los dos conjuntamente (efecto de interacción). Para ello sería necesario un experimento más extenso, con tratamientos adicionales que den luces sobre este hecho. Si el propósito es encontrar el mejor de los tratamientos “prácticos”, entonces ciertos tratamientos pueden omitirse por su no “practicidad”.
2. La respuesta, en algunos casos, puede deberse a las condiciones bajo las cuales se aplica un tratamiento dependiendo del medio circundante a este, lo que quizá tenderá a favorecer su efecto sobre las unidades experimentales. Esta situación es muy frecuente en trabajos con sustancias químicas aplicadas sobre suelos, en los que el efecto sobre las plantas se ve comprometido debido a los componentes del terreno o de las plantas mismas. Luego, debe decidirse si habrá controles sobre el terreno. Por ejemplo, homogenizando el suelo mediante la aplicación de estos componentes en cantidades considerables. Estas decisiones se toman previamente al análisis de suelos. No se debe perder de vista la población sobre la cual se desea hacer inferencia, porque un procedimiento como el descrito tal vez cambie la población objetivo.

3. Los tratamientos propuestos, generalmente, no son los que en la práctica se prueban. Por desconocimiento, descuido, por materiales o tipo de instrumentos, etc., se obtienen tratamientos diferentes a los de interés (de acuerdo con la planeación). Un caso común es cuando un tratamiento ha sido definido para ser aplicado de una forma específica y resulta aplicándose de otra. Por ejemplo, una sustancia para controlar plagas, la cantidad aplicada puede ser alterada o el momento de su aplicación puede ser diferente. Aquí, de una parte se ha modificado la dosis, de otra, el tiempo hace que los insectos (ácaros, mosca blanca, trips, araña blanca, etc.) a controlar estén posiblemente en una etapa de su desarrollo diferente a la prevista. Siendo “extremistas”, se puede afirmar que la mayoría de los tratamientos en el acto no corresponden a la definición original. Por ejemplo, por más cuidado que se tenga en mantener una cámara de muchas temperaturas se procura naturalmente que estas estén muy cerca de 20°C .
4. En muchos experimentos se presenta la necesidad de un tratamiento testigo o control. Este término refiere a un tratamiento en el que no se tiene un interés particular, pero puede servir de punto de comparación para revelar si los demás tratamientos son efectivos o mejores frente al testigo. Se recomienda la inclusión de un testigo cuando las condiciones físicas, químicas u ambientales, etc., en las que se aplican los tratamientos enmascaran, “oscurecen” la relevancia de estos. Por ejemplo, el caso en que la fertilidad de un terreno es muy alta tenderá a esconder el efecto del nutriente adicional. Otras situaciones se presentan en animales, en los cuales sus rasgos genéticos, condiciones fisiológicas o morfológicas no revelarán claramente la efectividad de las dietas en la ganancia de peso. Otra justificación para la consideración de un testigo suele ser cuando existe un desconocimiento muy alto acerca de la efectividad de los tratamientos objetos de estudio.

1.6. Control de la variación del no tratamiento

Para hacer válida la comparación entre tratamientos, se debe separar los efectos de fuentes extrañas de variación de los efectos de tratamientos y de la estimación del error experimental. Si esto no se puede hacer, se obtendrán estimaciones sesgadas tanto de las diferencias de tratamientos como del error experimental. Lo que se necesita son métodos a través de los cuales

la variación debida a fuentes distintas a los tratamientos sea controlada, de tal forma que los efectos de los tratamientos puedan ser estimados en forma segura y adecuada. Los métodos que hacen esta distinción están referenciados en forma conjunta como control del error.

El objetivo principal de estos métodos es obtener un estimador insesgado del error experimental, resultante de mejorar la precisión asociada con la estimación de las diferencias entre tratamientos. Estos métodos pueden ser experimentales (técnicos) o estadísticos.

Los métodos experimentales son aquellos impuestos por el experimentador, se destacan los siguientes.

- *Selección de más unidades experimentales homogéneas.* Esto incluye producir condiciones ambientales más uniformes con el fin de mantener las variables potenciales “constantes”. El criterio para la selección del material debería ser obtener el máximo beneficio con unos recursos dados (generalmente escasos). Sin embargo, el experimentador está limitado a la disponibilidad de material con el cual debe realizar el estudio, aunque tenga pocas alternativas de elección en la UE a ser usada. Consecuentemente, el uso de más unidades experimentales homogéneas no siempre es posible. Las unidades experimentales deben ser lo mas “representativas” de la población, ya que a partir de ellas se van a sacar las conclusiones sobre los tratamientos. Por esta razón, controlando experimentalmente algunos factores extraños y manteniéndolos constantes en algún valor específico puede limitar seriamente la aplicabilidad de los resultados experimentales.
- *Refinamiento de las técnicas experimentales.* La técnica experimental es responsabilidad del experimentador y debe ser siempre examinada para asegurar que sea lo más precisa posible. En la mayoría de ocasiones, la variabilidad asociada con una técnica determinada es relativamente pequeña, y hasta ahora solo se ha podido obtener un limitado mejoramiento en la precisión del experimento. Hay casos donde los errores de la técnica aumentan considerablemente la variabilidad. Tales errores deben prevenirse pero no sobredimensionarse.

Las técnicas estadísticas son métodos que ayudan a caracterizar los tratamientos (diseño experimental) y cuando hay información disponible adicional de tipo cuantitativo o cualitativo (análisis de covarianza) se tienen más ventajas. Una función básica del diseño de experimentos es controlar el ambiente experimental, dado que el control de dichos factores es costoso y tedioso. Es a través del diseño de experimentos que las fuentes conocidas

de variabilidad se controlan. Esto se consigue organizando las unidades experimentales en subgrupos más homogéneos, conocidos como bloques, los cuales están basados en “valores” comunes de los factores de clasificación. Haciendo esto, algunas de las variaciones naturales entre unidades experimentales son asociadas con otro factor cuya contribución a la estimación del error experimental puede ser eliminada.

En muchos experimentos, la precisión de la comparación de tratamientos puede ser aumentada usando variables concomitantes y/o auxiliares. Este tipo de análisis, conocido como análisis de covarianza, se recomienda cuando la variación entre unidades experimentales es, en parte, debida a la variación en algún otro carácter medible no suficientemente controlable, para ser usada en la asignación de las unidades experimentales a los bloques sobre las bases de resultados similares. Frecuentemente, la agrupación de estas variables cuantitativas en bloques, contruidos a partir de rangos de valores, no es efectiva, ya que la variación dentro de bloques puede ser más grande. Mas aún, se pueden requerir muchos grados de libertad para *controlar* este factor. Este aumento de los grados de libertad puede ser usado para estimar el error experimental.

El control estadístico a través del uso de bloqueo y/o el análisis de la covarianza elimina la variación debida a fuentes extrañas conocidas. Es a través de la aplicación de la aleatorización como las fuentes de variación desconocidas para el experimentador pueden ser controladas. El concepto de aleatorización y su función se discutirán más adelante.

El incremento en las replicaciones no reduce el error de la varianza, pero mejora la precisión de las estimaciones, dado que el error estándar se disminuye proporcionalmente a la raíz cuadrada del tamaño de la muestra ($\sigma/\sqrt{n}$). Este incremento en la “cantidad de reducción”, que debe realizarse aumentando las replicaciones, solo deberá realizarse cuando todas las demás opciones han sido eliminadas y la precisión deseada no ha sido obtenida.

1.7. Propiedades del diseño estadístico

Finney (1955) establece que por *diseño de experimentos* se entiende:

- Especificaciones de las unidades experimentales a las cuales los tratamientos han sido aplicados.
- Especificaciones de mediciones que pueden ser tomadas en cada UE.
- Selección de un grupo de tratamientos para comparación. Si bien la responsabilidad principal es del experimentador, la estadística

contribuye en la elección óptima de las combinaciones de tratamientos a ser usadas. Por ejemplo, en un experimento factorial fraccionado o en la exploración de *superficies de respuesta*. Esto se conoce como un diseño de tratamientos.

- La asignación de los tratamientos a las unidades experimentales (aleatorización) es lo que caracteriza el diseño estadístico de experimentos.

El diseño estadístico de experimentos es esencialmente el plan para poner a funcionar el experimento, especificando el arreglo de las unidades experimentales en el tiempo y/o espacio, y el patrón de observaciones que va a reportar información.

Por lo tanto, el diseño es una secuencia compleja de etapas proyectadas para garantizar que los datos sean obtenidos de tal manera que permitan un análisis objetivo, soportado en inferencias válidas respecto al planteamiento del problema, el cual debe ser lo más preciso posible y, además, viable económicamente.

El diseño de un experimento es una función importante, dado que ninguna técnica estadística puede revelar información no implícita inicialmente en los datos. Para cualquier grupo de datos, el análisis apropiado de estos es determinado por el diseño de experimentos. Por lo tanto, la habilidad de obtener un análisis significativo se basa inicialmente en la forma en que se han recolectado los datos. *Un buen diseño experimental es aquel que proporciona la información requerida con el mínimo esfuerzo experimental.* Muchos criterios han sido propuestos para contar con un experimento estadísticamente válido. En general, los requisitos estadísticos para el buen diseño de experimentos son:

- *Proveer estimaciones insesgadas para los efectos de los tratamientos.* Hasta donde es posible la comparación de tratamientos debe estar libre de sesgos sistemáticos. Es de primordial importancia que estas comparaciones reflejen diferencias debidas a los tratamientos y no a diferencias inherentes a las unidades experimentales. Es importante que el experimento esté diseñado para asegurar que las unidades experimentales que reciban un tratamiento específico no difieran de otros tratamientos.
- *Requerir que la precisión asociada con la estimación de efectos esté determinada al mismo tiempo que las estimaciones mismas.* En este sentido, el experimento está autocontenido. Para ello, debe haber una medición del error experimental. Esta estimación es necesaria para asegurar el nivel de significación estadística de las diferencias de tratamientos. Si dicha estimación es sesgada, se presentará una pérdida de eficiencia del

experimento, lo cual conllevaría a un desperdicio de tiempo, materiales y dinero. Si el experimento no provee una estimación del error experimental, será necesario usar una estimación de un experimento previo. La validez del procedimiento se basa en el hecho de que la magnitud del error experimental deberá permanecer invariante desde el último experimento (un supuesto que frecuentemente es insostenible).

- *Las comparaciones de tratamientos deben ser lo suficientemente precisas para detectar las mínimas diferencias de importancia práctica para el investigador.* Cuando se comparan tratamientos, si existen unas mínimas diferencias, esto proveerá una ganancia real. Así, si un tratamiento debe ser cambiado por otro, este debe ser mejor, aunque sea por una mínima diferencia. Claramente el experimento deberá tener suficiente precisión para detectar tales diferencias o, de lo contrario, no tendrá sentido realizarlo. La precisión de un determinado experimento dependerá de:
 - i. La variabilidad intrínseca del material experimental y de la precisión del trabajo experimental.
 - ii. La cantidad de replicaciones del tratamiento.
 - iii. El diseño del experimento.
- *Las conclusiones tienen un rango amplio de validez.* Las condiciones encontradas en la práctica nunca serán exactamente las obtenidas cuando se lleva a cabo el experimento. Se debe procurar que las conclusiones sobre los resultados del experimento se hagan sobre condiciones similares del experimento. Si las conclusiones se aplican, deberá haber confiabilidad de que las condiciones donde se apliquen sean similares. Cumpliendo esto, el experimento podrá tener un rango amplio de validez. Entre más amplio sea el rango de condiciones investigadas en el experimento, mayor será la confiabilidad de estas conclusiones cuando no se cumplan las condiciones de homogeneidad. Se debe tener cuidado de verificar que la organización del experimento no se torne muy compleja y no olvidar que si un grupo de tratamientos no es investigado totalmente, no se podrán obtener conclusiones significativas.
- *El diseño debe ser lo más simple posible para alcanzar los objetivos del experimento.* La selección del diseño depende de la naturaleza de las fuentes de variación en el material experimental. Se debe elegir el diseño más simple posible que permita controlar adecuadamente la variabilidad

conocida. A medida que el diseño experimental se torna más complejo hay una menor flexibilidad. Esto hace difícil la organización y puede llevar a cometer errores cuando se realiza el experimento. Entre más simple el diseño más fácil será llevar a cabo los ajustes necesarios, debido a las equivocaciones que siempre suelen aparecer.

Un buen diseño de experimento puede ser obtenido al aplicar los principios básicos establecidos por Fisher (1935). Estos son:

1. Replicaciones de algunos o todos los tratamientos para estimar la magnitud del error experimental.
2. Aleatorización de los tratamientos a las unidades experimentales para tener así una estimación válida del error experimental y estimaciones insesgadas de los efectos de los tratamientos.
3. El uso del control local de fuentes de variación extrañas conocidas a través de la construcción de sub-grupos homogéneos de unidades experimentales.




Figura 1.1: Diagrama de Fisher “Principios de la experimentación”.

De acuerdo con la figura 1.1, según las condiciones del experimento se escoge el diseño experimental, se formula un modelo lineal apropiado y se lleva a cabo el análisis estadístico basado en la escogencia del diseño y del modelo.

Para mayor claridad, en las siguientes secciones se lleva a cabo una explicación más amplia de estos principios.

1.8. Replicación

Definición 1.5. El proceso de repetir en condiciones similares el experimento para cada tratamiento se denomina *replicación*. Cuando el número

de replicaciones es igual para todos los tratamientos, el diseño se denomina *balanceado*, en caso contrario, se dice que es *desbalanceado*. Un número adecuado de replicaciones permite al experimentador obtener una estimación del error experimental.

La replicación es la asignación del mismo tratamiento a más unidades experimentales, o sea, hace referencia al número de unidades experimentales de cada tratamiento, no al número de observaciones. El propósito de la réplica es proveer una estimación del error experimental, que se obtiene al comparar unidades experimentales tratadas igual, pero que antes del experimento eran tratadas de manera diferente. Las múltiples mediciones tomadas en una UE no satisfacen esta definición, dado que esto no es replicación. Las repeticiones reducen la variación asociada con mediciones y/o errores muestrales, pero no proveen ninguna información relacionada con los errores experimentales.

Además de proveer una estimación de error experimental, las replicaciones aportan a la precisión del experimento al reducir el error estándar asociado con la comparación de tratamientos. Esto se desprende del hecho de que la varianza de la media disminuye inversamente proporcional a la raíz cuadrada del número de réplicas, controlando de esta forma el tamaño de la varianza del error.

A pesar que el incremento en el número de replicaciones da precisión a las estimaciones, estas no se pueden incrementar indefinidamente. Un punto para su disminución se alcanza cuando el incremento en los costos de la experimentación no es compensado con una reducción en la varianza. Cuando el número de réplicas se torna demasiado grande y las diferencias detectadas entre tratamientos son demasiado pequeñas, hay en la práctica una pérdida de recursos valiosos.

Las replicaciones incrementan el rango de las condiciones estudiadas en el experimento. No hay requisitos para que las replicaciones sean adyacentes en tiempo o espacio, dado que cuando se usan conjuntamente con el control local se puede investigar un mejor rango de condiciones experimentadas.

1.9. Aleatorización

La aleatorización es fundamental para tener un diseño de experimentos válido, es el procedimiento que permite a cada UE tener iguales condiciones para recibir cualquier tratamiento. Esto no significa que el experimentador podrá escribir como quiera la identificación de tratamientos (nombres o símbolos) en el orden que se le ocurra. La aleatorización es un proceso

físico en donde cada tratamiento tiene igual probabilidad de ser asignado a cualquier UE. En este punto, las leyes de aleatorización son explícitamente introducidas en el procedimiento experimental. De acuerdo con Brownlee (1957), una de las principales contribuciones que el estadístico puede hacer es insistir en la aleatorización del experimento.

La aleatorización es necesaria, ya que provee las bases para obtener una prueba válida de significación al destruir cualquier sistema de correlación que pueda existir entre las unidades experimentales. Un supuesto válido en el análisis de varianza es que los errores experimentales son independientes. En el caso de unidades experimentales adyacentes en tiempo y/o espacio, los errores asociados están correlacionados. Una correlación positiva entre las unidades experimentales tiene una mayor varianza del tratamiento que si las observaciones fueran independientes. Consecuentemente, la probabilidad del error tipo I será mayor que el valor pre-establecido. Con una correlación negativa los efectos son opuestos a aquellos con una correlación positiva. Al asignar los tratamientos aleatoriamente a las unidades experimentales, posiblemente sujetas a restricciones, el efecto de correlación se disminuye entre las unidades experimentales. La aleatorización no hace que los errores sean independientes pero asegura que, en promedio, las correlaciones sean cero. Como resultado, los datos pueden ser analizados si el supuesto de independencia de los errores es verdadero.

Una segunda función de la aleatorización es dar medios para evitar sesgos en la estimación del error experimental y los efectos de tratamiento. La estimación del error experimental se obtiene comparando las unidades experimentales tratadas de manera similar. Para que esta estimación sea válida, es necesario garantizar que las unidades experimentales tratadas de manera similar no sean diferenciables de manera relevante de las unidades experimentales tratadas de manera distinta. Una estimación del error válida se obtiene realizando una asignación aleatoria de los tratamientos a las unidades experimentales.

La aleatorización también proporciona estimaciones insesgadas de los efectos de los tratamientos al controlar los efectos de las fuentes de variación desconocidas. Es así como se tiene la seguridad de haber asignado adecuadamente estas fuentes de variación, las cuales deben ceñirse a normas. Esta es la única forma de asegurar que la comparación entre tratamientos no sea sesgada por un tratamiento que fue asignado de manera premeditada para hacer *mejores* o *peores* algunas unidades experimentales. La aleatorización romperá cualquier patrón asociado con factores desconocidos de tal forma que ningún tratamiento será favorecido respecto a los demás. La aleatorización nunca elimina la variación causada por factores extraños y/o desconocidos, porque

sus efectos se distribuyen en promedio, equitativamente sobre todos esos factores extraños.

Finalmente, la aleatorización es necesaria para abolir los sesgos personales, conscientes e inconscientes, de los sujetos que intervienen en el experimento, incluyendo al experimentador. La historia cuenta con un gran número de experimentos en Inglaterra sobre efectos de comida suplementaria para colegios de niños en distritos pobres que fueron inválidos porque la selección de los niños fue dejada en manos de los profesores, y ellos asignaron el mejor suplemento a los niños más desnutridos.

Hay un problema que aparece al aplicar la aleatorización cuando el número de unidades experimentales es muy pequeño. En estos casos, es posible que los arreglos producidos por la aleatorización sean para el experimentador deseables o inaceptables. Por ejemplo, la secuencia

AAABBBCCC

es apenas una forma de las 1670 secuencias posibles de tres tratamientos con tres réplicas en el tiempo. Sin embargo, este patrón probablemente no será aceptado por la mayoría de experimentadores. Tal relación sugiere una falta de conocimiento por parte del experimentador. Youden (1964) sugiere tres formas para manejar esta dificultad, todas ellas colocando restricciones a la aleatorización:

1. Incorporar al diseño de experimentos la condición que hace el arreglo inaceptable. Esta sería la mejor forma para manejar el problema. Sin embargo, tal vez no sea práctico o deseable para introducir estas futuras restricciones al diseño, ya que puede ocurrir que:
 - a) Pierda grados de libertad en la estimación del error experimental debido a la eliminación de la otra fuente de variación que puede no estar completamente compensada.
 - b) El experimento se vuelve más complicado.
 - c) Se hayan usado distintos sistemas de agrupación.
2. Rechazar arreglos extremos cuando ellos ocurran y *re-aleatorizar*. El mayor problema aquí será determinar subjetivamente qué es un arreglo extremo. Si esto se puede hacer, entonces esta será una solución más razonable.
3. Seleccionar un diseño aleatorizado de un grupo predeterminado de arreglos *aceptables*.

1.10. Control local

Definición 1.6. Al proceso de clasificación de las unidades experimentales en grupos homogéneos se le denomina *control local* o *bloqueo*.

Ejemplo 1.4. Si en el ejemplo 1.3 se controla el nivel de fertilidad del terreno, se determinan unidades homogéneas de terreno llamadas bloques, se subdivide cada bloque en parcelas, de igual área preferiblemente, y se aleatorizan sobre estas los tratamientos buscando que cada UE reciba un único tratamiento y que la totalidad de los tratamientos estén en cada bloque (caso de bloques completos).

Una función primaria del diseño de experimentos es reducir el control “exacto” del ambiente experimental debido a que tal control es un hecho costoso, tedioso y difícil de presentarse en la práctica, y presume que todos los factores influyentes han sido identificados. La función principal del control local es eliminar los efectos de fuentes conocidas de variación extrema.

El bloqueo es un arreglo de unidades experimentales en grupos homogéneos, basados en características comunes de los factores de clasificación. Los tratamientos se asignan a las unidades experimentales según la estructura de bloques. Así, el uso de control local coloca algunas restricciones en la asignación de los tratamientos a las unidades experimentales. Para alcanzar la máxima eficiencia con el bloqueo, es necesario el conocimiento relacionado con diversos factores extraños que pueden afectar las unidades experimentales, información que solo el experimentador puede proveer.

El bloqueo a las unidades experimentales se debe hacer de tal manera que se asocien a fuentes de variación extrema con diferencias entre bloques. En este caso, se debe cumplir que:

1. Se debe obtener una estimación más precisa del error experimental, puesto que la contribución de factores extraños se elimina, introduciendo además eficiencia al experimento debido a que se podrán detectar menores diferencias entre los tratamientos.
2. Las comparaciones de tratamientos no serán sesgadas por diferencias en las unidades experimentales debido a los factores externos.

La aplicación de control local (bloqueo) no remueve el requisito de aleatorización solo impone restricciones al tope de aleatorización que se llevará a cabo. Para todos los diseños, la asignación aleatoria de tratamientos a las unidades experimentales dentro de los límites impuestos por el control local es esencial para tener una interpretación válida de los resultados.

La relación de los tres principios básicos de un buen diseño de experimentos es la clave de la estructura que provee una estimación del error experimental y, a través de la aleatorización, asegura la validez de las estimaciones y de las pruebas de significación. La replicación también trae consigo una reducción de los errores de estimación, directamente por medio de la relación $\frac{\sigma}{\sqrt{n}}$ e indirectamente a través de la determinación de un sistema de control local.

1.11. Clasificación de los diseños

El diseño de un experimento depende solamente de los supuestos relacionados con las propiedades de las unidades experimentales, esencialmente, tales características determinan las restricciones que deben ser impuestas al aleatorizar los tratamientos respecto a las unidades experimentales, las cuales a su vez determinan el tipo de diseño experimental, el cual se puede clasificar como sistemático y aleatorizado.

Los diseños sistemáticos poseen un patrón regular para la asignación de tratamientos a las unidades experimentales. Las razones dadas para usar un diseño sistemático frecuentemente son:

- i. *Simplicidad*, siendo sencillo de aplicar.
- ii. Proporciona un muestreo *adecuado* del material experimental.
- iii. Lleva a “*colocaciones inteligentes*” u ordenamiento natural de los tratamientos, por ejemplo, las variedades pueden ser ordenadas de acuerdo con su madurez.
- iv. La aleatorización no es necesaria, dado que la heterogeneidad de las unidades experimentales por si solas aleatorizan los efectos de tratamientos.

Las desventajas de los diseños sistemáticos son:

1. El arreglo de los tratamientos puede combinarse con un patrón de variaciones no controladas, las cuales producen errores sistemáticos en la estimación de los efectos del tratamiento.
2. No hay una estimación válida de la varianza del error.

En los experimentos aleatorizados, la aleatorización elimina esta desventaja. Esta es la razón para que estos experimentos sean de tanta importancia. Estos experimentos pueden ser subdivididos de acuerdo con las siguientes

restricciones: ninguna (irrestricto), única y múltiple. De acuerdo con las restricciones impuestas, los diseños pueden ser clasificados como completos e incompletos, dependiendo si los tratamientos ocurren con la misma frecuencia o no, dentro de cada restricción que se le impone al experimento que se ha diseñado. Los diseños de bloques incompletos serán clasificados después como *balanceados* o *parcialmente balanceados*, dependiendo de la varianza asociada con las comparaciones pareadas.

Al seleccionar un diseño se deberá elegir el más simple que satisfaga los requisitos del experimento elegido. Si ningún diseño conocido está disponible para el análisis, este deberá ser construido. Un axioma básico es diseñar para el experimento y no experimentar para el diseño. Hay investigadores que piensan que la elección del diseño y/o tratamientos experimentales deben estar limitados a aquellos que aparecen publicados en la literatura especializada. De esta forma, se fuerza innecesariamente al experimentador a modificar el experimento y a ajustarlo al diseño conocido. Aun cuando un diseño estándar haya sido usado para determinar si los objetivos del experimento han sido logrados, siempre se hace necesaria la verificación y su análisis estadístico. En la tabla 1.1 se presenta un resumen de lo expuesto en esta sección.

Tabla 1.1: Clasificación de los diseños, según Martín (1989)

1. *Sistemático*. Los tratamientos son asignados a las unidades experimentales de acuerdo con algún patrón predeterminado. Estos diseños no proveen estimaciones válidas del error experimental.
2. *Aleatorizados*. La asignación de los tratamientos a las unidades experimentales depende de algún patrón de aleatorización. Solo para estos diseños las técnicas de análisis de varianza son válidas.
 - a) *Irrestritos*. La aleatorización no está restringida a ningún arreglo de las unidades experimentales.
 - b) *Restricción única*. La aleatorización se restringe a un único requisito determinado en el arreglo de las unidades experimentales. Estos son los diseños de bloques.
 - c) *Restricciones múltiples*. La aleatorización se restringe a dos o más requisitos localizados en los arreglos de las unidades experimentales. La misma sub-clase general existe para estos diseños como, en el caso de los diseños de bloques.

Esta clase de experimentos pueden ser:

- *Balanceados*. Se obtiene la misma precisión para cada par de comparaciones entre tratamientos.
 - *Parcialmente balanceados*. La precisión no es constante para cada par de comparaciones, pero depende de los tratamientos involucrados.
-

1.12. Estrategia de diseño

En la selección de un diseño experimental se deben tener en cuenta las características propias de la disciplina en donde se realiza; a pesar de que los principios estadísticos son los mismos, las estrategias frecuentemente son distintas. La estrategia experimental depende del tiempo para realizar el experimento, el costo de la experimentación y la cantidad de variación en el material experimental.

El hecho de que no haya una única estrategia de experimentación permite que pueda ser ilustrada por la comparación entre los experimentos agrícolas y los industriales. En general, los experimentos agrícolas: (a) requieren un tiempo más largo, frecuentemente meses y, en algunos casos, hasta años, por ejemplo, cuando se relacionan con cultivos perennes, y (b) usualmente presentan una mayor variabilidad entre las unidades experimentales. Es casi imposible alterar o modificar estos experimentos una vez han comenzado. Consecuentemente, el campo de la experimentación agrícola debe estar autocontenido, por lo que frecuentemente involucra diseños más amplios, comprensivos y complejos. De esta manera, se puede obtener mucha información de cada experimento.

Por el otro lado, la mayoría de experimentos industriales satisfacen que: (a) la capacidad para realizar experimentos es muy rápida, el tiempo de intervalo puede ser uno o unos pocos días, inclusive horas, y (b) la variación natural entre las unidades experimentales es generalmente muy pequeña. Más aún, la mayoría de la experimentación se hace secuencialmente, dado que los resultados están disponibles para su análisis antes de terminar el experimento. Como resultado, hay una gran flexibilidad. Además, debido a que cada observación o grupo de observaciones están disponibles, la situación puede ser revisada antes de comenzar un próximo grupo de ensayos. Con base en los resultados, la decisión sobre la cuestión “qué hacer luego” permite crear ajustes en el diseño de experimentos. Consecuentemente, se pueden usar secuencias de experimentos más pequeños y simples, esta es una ventaja.

Box (1957) notó una paradoja interesante respecto al diseño de programas experimentales. El único tiempo en el cual el programa de experimentación puede ser diseñado adecuadamente es después de haber sido culminado. Es común encontrar en la culminación de un programa que:

1. Una o más variables probablemente hayan sido omitidas del experimento.

2. Una o más variables originalmente incluidas en el experimento aparezcan con un pequeño efecto. Por lo tanto, no son tan importantes como se pensó al principio.
3. Un diseño experimental más complejo se necesita para solucionar adecuadamente los problemas.
4. Algunas transformaciones a las variables podrán ser apropiadas.

La experimentación deberá involucrar indeterminaciones como el hecho de que dos experimentadores, que estudian el mismo problema, tengan la misma opinión en relación con estos ítems. Si se determina una serie de normas sobre sistemas de experimentación rígidos que pueda abolir estas dificultades, tendrá como único resultado el sacrificio en el conocimiento del experimentador, su experiencia e imaginación.

1.12.1. Efecto de diseño de control del error

En la tabla 1.2 se presentan las clases de diseños de control del error en orden ascendente de complejidad en modelos aleatorizados según la propuesta de Hinkelman y Kempthorne (1994), en la cual estos están definidos por el número de factores de bloqueo por clase. Los factores de bloqueo corresponden a diferentes variaciones sistemáticas. La idea de los diseños de control del error es reducir el error experimental a través del bloqueo de los tratamientos, permitiendo esencialmente que el material experimental quede en grupos más homogéneos.

1.12.2. Diseño de tratamientos

Cada uno de los diseños que controlan el error mencionados en la tabla 1.2 se usa con el fin de comparar los tratamientos entre sí. Sin embargo, los tratamientos son seleccionados según alguna estructura, en particular una estructura factorial, la cual se refiere al diseño de los tratamientos. Estos se seleccionan de acuerdo con las metas o intereses de la investigación, el material experimental y los factores disponibles. La escogencia de los tratamientos estará enmarcada dentro de un apropiado diseño que controla el error, como se mostró en la sección anterior. Dentro de la estructura factorial de tratamientos se conocen dos clases: las estructuras factoriales simétricas y las estructuras factoriales asimétricas. En la primera, se tienen k factores cada uno con s niveles, donde s es un entero. En este caso, se tienen s^k tratamientos. En la segunda estructura, se tienen k_1 factores con s_1 niveles,

k_2 factores con s_2 niveles, $\dots$, k_m factores con s_m niveles. En esta estructura, se tiene un total de $t = s_1^{k_1} s_2^{k_2} \dots s_m^{k_m} = \prod_{j=1}^m s_j^{k_j}$ tratamientos.

Tabla 1.2: Efectos de diseño de control del error

Factores de control del diseño aleatorizado	Tipo de diseño	Caracterización
0	Diseño completamente aleatorizado	
		1. Diseño en bloques completamente aleatorizado (todos los tratamientos aparecen dentro de un bloque por lo menos una vez). 2. Diseño en bloques aleatorizado generalizado. 3. Diseño en bloques incompletos: a) Diseños en bloques incompletos balanceados. b) Diseños en bloques incompletos parcialmente balanceados. c) Diseños en bloques incompletos con tratamientos balanceados. 4. Diseños en bloques extendidos. 5. Diseños en bloques por franjas.
1	Diseño en bloques aleatorizado	
2	Diseño en cuadros latinos	1. Diseño en cuadro latino. 2. Rectángulos latinos. 3. Diseño en cuadro latino incompleto (cuadrado de Youden). 4. Diseño Cross-over.
3	Diseño en cuadro latino replicado. Cuadros grecolatinos.	
> 3	Series de cuadros latinos mutuamente ortogonales.	

Cuando se desea reducir el tamaño del experimento, consideración motivada muchas veces por cuestiones de tiempo y costos, se trabaja con un

diseño de tratamientos factorial fraccionado. De acuerdo con Hinkelman y Kempthorne (1994), los anteriores resultados se pueden resumir en la tabla 1.3.

Tabla 1.3: Resumen de los diferentes diseños de tratamientos

Tipo de factorial	N° de factores	N° de niveles	Total de trats.
Simétrico	k	s	s^k
Asimétrico	$k_1 + k_2 + \cdots + k_m$	$s_1 + s_2 + \cdots + s_m$	$\prod_{j=1}^m s_j^{k_j}$
Fracción (simétrica)	k	s	s^{k-p}
Fracción (asimétrica)	$k_1 + k_2 + \cdots + k_m$	$s_1 + s_2 + \cdots + s_m$	$\prod_{j=1}^m s_j^{k_j-p_j}$

1.12.3. Diseño de muestreo

Lo más importante de un diseño de control del error con submuestreo es la separación del error experimental y el error observacional (o de muestreo); o más precisamente, la separación de la varianza del error experimental y el observacional.

La noción de submuestreo puede obviamente ser extendida a más de un nivel, por ejemplo, para cada UE se pueden tener algunas unidades muestrales y luego para cada unidad muestral se pueden tener algunas unidades observacionales. En la tabla 1.4 se resumen los resultados, de acuerdo con Hinkelman y Kempthorne (1994), para los diseños con submuestreo.

Tabla 1.4: Estructura general de un diseño de muestreo

Tipo de diseño	N° de UE por trat.	N° de sub- muestras por UE	N° de sub- muestras por submuestra	N° de obs. por trat.
Sin submuestreo (UE=UO)	r	1		r
Submuestreo	r'	n		$r'n$
Sub-submuestreo	r''	n'	m	$r''n'm$

1.13. Recomendaciones para abordar un estudio experimental

Para que el experimento sea exitoso, se deben tener en cuenta las siguientes recomendaciones, de acuerdo con Hinkelman y Kempthorne (1994):

1. *Conocimiento claro del material experimental.* Aunque parezca obvio, en la práctica no siempre el desarrollo de un problema requiere de experimentación ni es simple presentar un claro y apropiado estado del problema. Es necesario abordar todas las ideas sobre los objetivos del trabajo. Un adecuado conocimiento del estado del problema frecuentemente contribuye a un mejor entendimiento del fenómeno y a una solución del problema.
2. *Escogencia de factores y niveles.* El experimentador debe seleccionar las variables independientes o factores a ser estudiados, estos pueden ser cuantitativos o cualitativos. En el caso de tener variables cualitativas, hay que tener en cuenta cómo se controlarán estas en los valores de referencia y cómo van a ser medidas (aquí es importante el conocimiento del investigador). Es conveniente seleccionar los rangos de variación de los factores y el número de niveles a considerar, los cuales pueden ser predeterminados o escogidos aleatoriamente del conjunto de los posibles niveles.
3. *Selección de las variables respuesta según los objetivos.* En la escogencia de la variable respuesta o variable dependiente, el experimentador ha de estar seguro que la respuesta a medir realmente provee información sobre el problema de interés. Es necesario que él suministre la forma en que se mide esta variable y, de ser posible, la probabilidad de ocurrencia de estas medidas.
4. *Selección del diseño experimental.* Este paso es muy importante en el proceso de investigación. Se debe indicar la diferencia en la respuesta verdadera (qué tan lejos se admite la realidad de lo observado) que se desea detectar y la magnitud de los riesgos tolerados (grado de confiabilidad), luego escoger un tamaño de muestra apropiado (replicaciones). Es procedente señalar también el orden de recolección de los datos y el método de aleatorización a emplear. Siempre es necesario mantener un equilibrio entre la exactitud y los costos. Se deben recomendar planes que sean eficientes estadísticamente y económicamente viables. En la conducción

de un estudio experimental es de esencial importancia la escogencia del diseño. Esta elección depende de cuatro componentes:

- *El diseño de tratamientos (DT)*. En esta etapa se determinan los tratamientos a ser medidos en el estudio, es decir, se establecen cuáles y cuántos tratamientos se deben aplicar teniendo en cuenta la naturaleza del experimento. Los tratamientos son determinados por factores o combinaciones de niveles de factores, como se observó en la tabla 1.3. El interés del investigador es relevante en el sentido de decidir cuántos factores deben incluirse, cuántos niveles de factores se deben identificar en cada factor y cuál es el rango razonable de cada factor. Los aspectos del diseño de tratamientos están estrechamente ligados con el diseño para controlar el error.
- *Diseño de control del error (DE)*. Por diseño de control del error se entiende la distribución aleatoria de los tratamientos en un plan experimental usando la regla de asignación aleatoria de los tratamientos a las unidades experimentales. Como ejemplos de control de error se tienen los diseños presentados en la tabla 1.2. La escogencia del diseño depende de la variabilidad de las unidades experimentales, la estructura de estas unidades y la precisión de la estimación deseada por el investigador.
- *Estructura del control del error (EE)*. Por esta se entiende la asignación aleatoria de los tratamientos a las unidades experimentales.
- *Muestreo y diseño de observaciones (DM)*. Hace referencia a la determinación del número de observaciones tomadas por tratamiento y UE, lo cual caracterizará los planes experimentales con submuestreo.

Una vez definidas las componentes anteriores, la respuesta (R) para el análisis seleccionado satisface la ecuación $R = DT + DE + EE + DM$; es decir, la formulación del modelo estadístico apropiado está relacionada con la estructura del diseño de tratamientos, el diseño del control del error y el muestreo de las observaciones.

El diseño seleccionado se asocia con un modelo lineal de la forma $Y = X\beta + \epsilon$, si el modelo es de efectos fijos, se descompone la variabilidad de la respuesta (variabilidad total) como una partición ortogonal de las diferentes fuentes de variabilidad, es decir,

$$SC(total) = \sum_{i=1}^q SC(i),$$

donde $SC(total) = Y^t Y$ y $SC(i) = Y^t P_{X_i} Y$ siendo

$$P_{X_i} = X_i (X_i^t X_i)^{-1} X_i^t,$$

con $i = 1, \dots, q$, el proyector ortogonal en el espacio columna de X_i , donde X_i es el bloque asociado con el i -ésimo factor de clasificación de la matriz $X = (X_1 : X_2 : \dots : X_q)$. Los conceptos anteriormente mencionados serán tratados con mayor detalle en el capítulo 3.

5. *Conducción del experimento.* Es el proceso de recolección de datos. Se entenderá que en el proceso haya un ajuste al plan (control). La mayoría de las veces la realización de un experimento no es lo suficientemente fiel al proyecto de investigación porque surgen situaciones no consideradas previamente, como en el caso de un cultivo atacado por plagas, el agotamiento producido sobre una UE que se está evaluando (por ejemplo, agotamiento de materiales) o la aparición de una característica no determinada. En todos los casos, se debe evaluar si estos imprevistos alteran los propósitos del ensayo. De cualquier forma, hay que tenerlos en cuenta en el análisis de los resultados.
6. *Análisis de datos.* Las variables que intervienen o, mejor, que se procura sean consideradas en un ensayo pueden relacionarse matemáticamente de alguna forma. El problema no está en la consecución de una expresión matemática, sino en qué tanto explica la realidad dicha expresión. Es preferible renunciar a un bello modelo que aceptar una realidad deformada por él. En esta etapa, se busca una ecuación matemática que explique el comportamiento de una(s) variable(s) a través del comportamiento de otras. Existen técnicas estadísticas, como el análisis de regresión, que suministran estas relaciones. Se debe buscar que el modelo se analice junto con el especialista del área de investigación.

Una vez se ha seleccionado el diseño experimental, se establece la matriz de diseño X , el vector de parámetros β y se asocia a un modelo $Y = X\beta + \epsilon$, el cual generalmente resulta ser de rango incompleto y estimado por el método denominado mínimos cuadrados o máxima verosimilitud a través de una matriz inversa generalizada de X (en el caso de no haber hecho reparametrización). Para la estimación del modelo y el análisis estadístico de los datos, se debe tener en cuenta:

- a) *Estimación de los parámetros del modelo.* Estimar mediante los métodos de mínimos cuadrados o máxima verosimilitud los parámetros asociados con el modelo. En este último método, se tiene

en cuenta la distribución de probabilidad de la variable respuesta. Por este motivo, la mayoría de los desarrollos realizados en este texto se hacen asumiendo que la variable respuesta sigue una distribución normal multivariada. Cuando el modelo es de rango incompleto, se realizan cálculos muy similares al caso de rango completo, con lo cual simplemente los estimadores son adaptados a este modelo.

- b) *La teoría de estimabilidad.* Conocer los principales criterios para caracterizar las funciones estimables.
- c) *Pruebas de hipótesis.* Conocer la estructura distribucional de los estadísticos de prueba para tomar decisiones sobre las hipótesis de interés.

Una parte del análisis es la verificación del modelo propuesto, lo cual conlleva un examen crítico de las bases del modelo estadístico y su relación con los supuestos (independencia, homogeneidad de varianza y normalidad, entre otros). En esta etapa, recientemente, el computador ha jugado un papel importante. Existen diferentes procedimientos y paquetes estadísticos que facilitan el análisis de los datos. Un paquete estadístico es un conjunto de programas elaborados para el procesamiento de información, los cuales se manipulan por medio de una serie de instrucciones y comandos dirigidos a resolver problemas de modelamiento estadístico. Entre los paquetes estadísticos de más amplia difusión en el área experimental se pueden mencionar: el SPSS (Statistical Package for Social Science), SAS (Statistical Analysis System), BMDP (Biomedical Package), MINITAB, Design Expert y software libre como el R.

7. *Conclusiones y recomendaciones.* Hecho el análisis de los datos, el experimentador puede extraer conclusiones (inferencia) sobre los resultados. Las inferencias estadísticas deben ser físicamente interpretadas y su significación práctica evaluada. Las recomendaciones deben hacerse con base en los resultados. En la presentación de estos debe evitarse el empleo de terminología estadística “seca” y, en lo posible, presentarlos de manera simple. La elaboración de gráficos y tablas evita la redacción de resultados y recomendaciones extensas y confusas; por ejemplo, diez pruebas t pueden ser más prácticas y entendibles que una prueba F .

1.14. Principio general de inferencia y tipos de análisis estadísticos

De acuerdo con Hinkelman y Kempthorne (1994), el modelo para la elaboración de un diseño experimental contiene cuatro componentes, como se mencionó en la sección 1.13. Estos se pueden representar mediante el siguiente modelo lineal

$$Y = \mathbf{1}\mu + \sum_{i=1}^t X_i \tau_i + \sum_{j=1}^b B_j \beta_j + \sum_{k=1}^c Z_k \epsilon_k + \sum_{s=1}^d W_s \eta_s, \quad (1.1)$$

donde Y es el vector de observaciones, μ es el efecto general de la media, $\tau_i = (\tau_{i1}, \dots, \tau_{i\alpha_i})$ es el vector de efectos de tratamientos ($i = 1, 2, \dots, t$), $\beta_j = (\beta_{j1}, \dots, \beta_{j\beta_j})$ es el vector de efectos del diseño ($j = 1, 2, \dots, b$), $\epsilon_k = (\epsilon_{k1}, \dots, \epsilon_{k\epsilon_k})$ es el vector asociado con el EE ($k = 1, 2, \dots, c$), $\eta_s = (\eta_{s1}, \dots, \eta_{s\eta_s})$ es el valor de error de las observaciones ($s = 1, 2, \dots, d$), $\mathbf{1}$ es el vector de unos de tamaño $n \times 1$ y X_i, B_j, Z_k, W_s son las matrices asociadas y conocidas de dimensiones apropiadas.

La estructura general del análisis de varianza, teniendo en cuenta el modelo (1.1), se presenta en la tabla 1.5.

Con la finalidad de ilustrar algunos de los resultados tratados en las secciones anteriores, se presenta el siguiente ejemplo tomado de Hinkelman y Kempthorne (1994).

Ejemplo 1.5. *Suponga que un investigador desea estudiar y comparar los efectos de agentes contaminantes en la plantación de semillas de pino. Se tiene como tratamiento control el aire del carbón filtrado (P_1) y se incluyen los siguientes agentes contaminantes: ozono (P_2), dióxido sulfúrico (P_3) y dióxido de nitrógeno (P_4). Este es un experimento exploratorio para el cual se tienen disponibles cuatro plantaciones de semilla para cada contaminante, es decir, 16 plantaciones en total. Se asume que las plantaciones son de la misma edad y de altura uniforme y que es razonable pensar en una fumigación previa para llevar un análisis apropiado.*

Las preguntas que surgen son ¿cuáles son los diseños alternativos para este experimento?, ¿cuál es el correspondiente modelo lineal?, ¿cómo se pueden analizar estos experimentos? y, la más importante, ¿qué respuestas proveen estos experimentos a las preguntas del investigador?

Siguiendo a Hinkelman y Kempthorne (1994), para dar solución a este problema se pueden plantear cuatro situaciones experimentales, las cuales son (estas no son necesariamente buenas):

Tabla 1.5: Estructura general de análisis de varianza para el modelo (1.1).
gl: Grados de libertad

Causas de variación		gl	
Entre U.E.		$m - 1$	
Entre tratamientos		$t - 1$	
Diseño de tratamientos	τ_1		t_1
	τ_2		t_2
	$\vdots$		$\vdots$
	τ_t		t_t
Entre UE dentro de tratamientos		$m - t$	
Diseño de control del error	β_1		d_1
	β_2		d_2
	$\vdots$		$\vdots$
	β_b		d_b
	ϵ_1		l_1
	$\vdots$		$\vdots$
	ϵ_c		l_c
Dentro UE		$n - m$	
Diseño de observaciones	η_1		0_1
	η_2		0_2
	$\vdots$		$\vdots$
	η_d		0_d
Total		$n - 1$	

Situación I: *cuatro camas con agentes contaminantes son usadas, cada cama contiene cuatro plantaciones. Los agentes contaminantes son asignados aleatoriamente a las camas como se muestra en la figura 1.2. La colección de camas constituye una UE, en la que cada plantación individual constituye la unidad observacional (UO). Como consecuencia, el efecto de tratamiento y el error experimental están confundidos entre sí.*

En este caso, el modelo propuesto tiene la forma

$$y_{ij} = \mu + P_i + \epsilon_i + \eta_{ij},$$

$i = 1, \dots, 4, j = 1, \dots, 4$, donde se asume que $\epsilon_i \stackrel{iid}{\sim} N(0, \sigma_\epsilon^2)$, $\eta_{ij} \stackrel{iid}{\sim} N(0, \sigma_\eta^2)$, $Cov(\epsilon_i, \eta_{ij}) = 0$, para todo ij , y P_i es un efecto fijo. Además, y_{ij} es la respuesta asociada a la j -ésima plantación, a la cual se le aplica el i -ésimo agente contaminante.

Los resultados de este arreglo se presentan en la tabla 1.6 del ANOVA. En este caso, la hipótesis nula de igualdad de tratamientos ($H_0 : P_1 = P_2 = P_3 = P_4$) no puede ser juzgada, ya que las esperanzas de los cuadrados medios del contaminante y, error experimental tienen el mismo valor esperado (ver tabla 1.6). Desde este

punto de vista, este experimento sería inadecuado, ya que no responde a las preguntas iniciales del investigador, puesto que no se puede encontrar una combinación lineal de los cuadrados medios en la cual se pueda aislar el efecto del agente contaminante (efecto de tratamiento).




Figura 1.2: Arreglo de campo para los datos de la situación I.

Tabla 1.6: Análisis de varianza para los datos de la situación I

Causas de variación	gl	E(CM)
Contaminante (+ error exper.)	3	$\sigma_{\eta}^2 + 4\sigma_{\epsilon}^2 + \frac{4}{3} \sum_{i=1}^4 P_i^2$
Error muestreo	12	σ_{η}^2

Situación II: *en este caso, cada plantación se coloca dentro de una cama separada, los contaminantes son asignados aleatoriamente a cada cama como se muestra en la figura 1.3. Las UE's y UO's son idénticas; de esta forma, los dos tipos asociados de errores no pueden ser separados uno del otro.*




Figura 1.3: Arreglo de campo para los datos de la situación II.

Para esta situación el modelo propuesto tiene la forma

$$Y_{ij} = \mu + P_i + \epsilon_{ij} + \eta_{ij},$$

con $i = 1, 2, 3, 4$ y $j = 1, 2, 3, 4$.

En este caso, los dos errores pueden ser separados del efecto de los tratamientos permitiendo la realización de la prueba de hipótesis de igualdad de tratamientos, pero no se puede realizar una estimación aislada de cada uno de los errores (experimental y muestral) por separado (ver tabla 1.7).

Tabla 1.7: Análisis de varianza para los datos de la situación II

Causas de variación	gl	E(CM)
Contaminante	3	$\sigma_\eta^2 + \sigma_\epsilon^2 + \frac{4}{3} \sum_{i=1}^4 P_i^2$
Error (expe. + obser.)	12	$\sigma_\eta^2 + \sigma_\epsilon^2$

Situación III: en el tercer caso, dos camas están disponibles para cada contaminante y en cada cama se asignan dos plantaciones. La variación entre camas (UE) tratada con el mismo contaminante es una medida del error experimental y la variación entre plantaciones (UO) dentro de cada cama es una medida del error de muestreo, como se ilustra en la figura 1.4.




Figura 1.4: Arreglo de campo para los datos de la situación III.

En esta situación se propone el modelo

$$Y_{ijk} = \mu + P_i + \epsilon_{ij} + \eta_{ijk}$$

$i = 1, 2, 3, 4$, $j = 1, 2$ y $k = 1, 2$, donde Y_{ijk} es la k -ésima observación para la j -ésima UE (réplica) del i -ésimo tratamiento.

Aquí no solamente los dos tipos de errores son separados entre sí, sino también del efecto del contaminante (ver tabla 1.8).

Tabla 1.8: Análisis de varianza para los datos de la situación III

Causas de variación	gl	E(CM)
Contaminante	3	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2 + \frac{4}{3} \sum_{i=1}^4 P_i^2$
Error experimental	4	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2$
Error muestreo	8	σ_{η}^2

Situación IV: *finalmente, esta situación representa una variación de la situación III en la que el contaminante se puede adecuar sobre cuatro camas con los agentes contaminantes uno en la mañana (M) y uno en la tarde (T), como se muestra en la figura 1.5. Esto es válido porque es de esperarse por el ritmo diurno de las plantas que haya diferencias sistemáticas entre las plantaciones en la mañana y en la tarde. Estas diferencias pueden ser eliminadas considerando los dos conjuntos de cuatro cuartos en cada bloque.*




Figura 1.5: Arreglo de campo para los datos de la situación IV.

El modelo propuesto para esta situación tiene la forma

$$Y_{ijk} = \mu + P_i + \beta_j + \epsilon_{ij} + \eta_{ijk},$$

con $i = 1, 2, 3, 4$, $j = 1, 2$ y $k = 1, 2$, donde Y_{ijk} es la k -ésima observación para el j -ésimo bloque del i -ésimo tratamiento.

Este arreglo puede llevar a una reducción en el error experimental y, además, en este caso, al igual que en la situación anterior, todos los efectos pueden ser separados (ver tabla 1.9).

Tabla 1.9: Análisis de varianza para los datos de la situación IV

Causas de variación	gl	E(CM)
Contaminante	3	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2 + \frac{4}{3} \sum_{i=1}^4 P_i^2$
Bloque	1	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2 + 8 \sum_{j=1}^2 \beta_j^2$
Error experimental	3	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2$
Error muestreo	8	σ_{η}^2

Las situaciones I, II y III son diferentes versiones de un diseño completamente aleatorizado y la situación IV representa un diseño en bloques completamente aleatorizado.

Solo se debe notar que el diseño I no debe ser utilizado y el uso de los otros arreglos debe ser determinado por consideraciones prácticas y condiciones propias del estudio.

Para más detalles y comentarios sobre estas situaciones, se recomienda la lectura del capítulo 2 del libro Hinkelman y Kempthorne (1994).


1.15. Ejercicios

1. Comente qué importancia tienen los diseños experimentales en la investigación experimental y qué aspectos se deben considerar dentro de la metodología experimental.
2. ¿Qué debe contener el capítulo de materiales y métodos de un proyecto o experimento respecto al diseño experimental?
3. ¿Cuáles serían las unidades experimentales, réplicas, unidades observacionales, tratamientos y el modelo matemático en las siguientes situaciones?
 - a. Un experimento en el que se examina la efectividad de varios antibióticos en animales de laboratorio.
 - b. Un estudio sobre fisiología de los ejercicios con voluntarios humanos, en el cual estos se someten a una prueba respiratoria y cardiovascular después de estar en una banda caminadora.
 - c. Se plantea un experimento con la finalidad de comparar tres métodos de enseñanza. Cada uno se aplica en un salón con 30 estudiantes.
4. Explique el significado y proponga al menos dos ejemplos de:

- a. Factor fijo.
 - b. Factor aleatorio.
 - c. Error experimental.
 - d. Unidad experimental.
 - e. Aleatorización de tratamientos.
5. Se investigó la pérdida de peso en porcentaje del peso inicial de la carne de res tipo milanesa, después de cinco días de empacada en cuatro tipos de envolturas: Icopor, Biopak, Cry-0-Pak y Shopak. Para tal finalidad se realizaron cinco replicaciones de cada una.
 - a. Describa los factores, niveles, unidades experimentales, unidades observacionales, tratamientos y la variable respuesta.
 - b. Diseñe una aleatorización correcta para este experimento y proponga el modelo lineal asociado.
6. Se investigó la morfometría de *J. Lamprotaenia* (sardina azul) en las islas del Rosario (Bolívar). Entre otras características, midieron la longitud estándar de sardinas hembras en tres estaciones de muestreo: fondo arenoso, manglar y pasto marino.
 - a. Describa los factores, niveles, unidades experimentales, unidades observacionales, tratamientos y la variable respuesta.
 - b. Diseñe una aleatorización correcta para este experimento y proponga el modelo lineal asociado.
7. Se midió la concentración de calcio en hojas de cinco especies de árboles para saber si el nitrógeno en tres niveles diferentes afectaba el porcentaje de peso seco de la hoja (esta es una forma de medir la concentración de calcio). De cada árbol se tomaron aleatoriamente cuatro hojas y se hicieron cuatro lecturas de cada hoja.
 - a. Lleve a cabo una descripción completa del experimento especificando: objetivos, población, factores, unidades experimentales, unidades observacionales, tratamientos y variable respuesta.
 - b. Indique un método de aleatorización apropiado para el experimento y el modelo lineal asociado.
8. Un experimentador está estudiando el efecto de diluentes de semen en la tasa de concepción en vacas lecheras, usando las variables: reductor (citrato o fosfato), sulfanilamina (sí o no) y la cantidad de penicilina (para la cual se seleccionaron tres niveles entre 0 y 500 miligramos).

- a. Defina los factores, los niveles asociados con estos y la variable respuesta en este experimento.
 - b. Defina la UE, los tratamientos y la clase de experimento.
 - c. Escriba el modelo lineal para el diseño propuesto en b., realizando los supuestos apropiados sobre el mismo.
9. Proponga un problema de investigación en algún área de su interés en el cual se pueda realizar un muestreo aleatorio de los tratamientos en el estudio de una población grande de tratamientos.
 - a. Describa el estudio y cómo lo realizaría.
 - b. Presente el modelo lineal para su estudio, identifique los factores, los tratamientos y las unidades experimentales.
 - c. ¿Qué suposiciones tendrá que hacer sobre su estudio para tener inferencias válidas?
10. Suponga que se planea investigar el efecto del salario y el tiempo de la jornada de trabajo sobre la producción de los trabajadores en una empresa manufacturera. Tanto el salario como el tiempo de la jornada de trabajo se establecerán en tres niveles y se observará la productividad en todas las combinaciones de estos factores.
 - a. Lleve a cabo una descripción completa del experimento especificando: objetivos, población, factores, unidades experimentales, unidades observacionales y variables respuesta.
 - b. Identifique los tratamientos y el tipo de experimento de que se trata.
 - c. Indique un método de aleatorización apropiado para el experimento.
11. Un grupo de investigadores trabaja para industrializar la mermelada de feijoa, para ello realizaron mermeladas considerando tres variedades de feijoa, con o sin cáscara, completa o la pulpa pura. Como parte del estudio se toman cuatro vasos de mermelada en cada tratamiento y cada uno de estos es evaluado por tres catadores que colocan una nota de 0 a 100, donde cero es un sabor muy desagradable y 100 es muy agradable.
 - a. Defina la unidad experimental, la unidad muestral (si la hay), los factores, los niveles, los tratamientos y la variable respuesta en este estudio.

- b. Proponga y haga los supuestos necesarios sobre el modelo para llevar a cabo el análisis de esta información. Enmárquelo dentro de los tres principios básicos del diseño de experimentos propuestos por Fisher.
12. Un grupo de investigadores trabaja para producir huevos de gallina con alto contenido de omega 3. Para ello se consideraron cuatro razas de gallina en cinco fincas seleccionadas aleatoriamente y tres tipos de alimentos (uno de ellos es un placebo). Como parte del estudio se toman tres huevos de cada gallina y cada uno de estos es evaluado por dos expertos que miden el contenido de omega 3 en el huevo.
 - a. Defina la unidad experimental, la unidad muestral (si la hay), los factores, los niveles, los tratamientos y la variable respuesta en este estudio.
 - b. Proponga y haga los supuestos necesarios sobre el modelo para llevar a cabo el análisis de esta información. Enmárquelo dentro de los tres principios básicos del diseño de experimentos propuestos por Fisher.



Capítulo dos Inferencia sobre dos muestras aleatorias

2.1. Introducción

Cuando el parámetro teórico es un valor control o estándar, este no es frecuentemente conocido bajo las condiciones particulares del experimento, por lo cual el investigador, a través de una muestra, obtiene un conjunto de observaciones a partir de las cuales se encuentran las estimaciones, permitiendo hacer inferencia sobre el(los) parámetro(s) poblacional(es) de interés.

Por otra parte, si las observaciones experimentales y de control son pareadas teniendo en cuenta algunas características de ruido con el fin de eliminar su efecto, las diferencias individuales se deben calcular para cada pareja y el problema se convierte en comparar las diferencias de medias. Cuando lo anterior no sucede, se tiene un problema con dos muestras independientes.

En este capítulo se expone el problema de comparar parámetros de dos poblaciones a partir de dos muestras aleatorias, con el propósito práctico de establecer si hay alguna ganancia en la repuesta de interés al aplicar o no un determinado tratamiento. La verificación de este tipo de hipótesis a partir de dos muestras aleatorias de las poblaciones de interés se decidirá con base en los datos contenidos en estas, lo cual proporciona evidencia que soporte o no la hipótesis de interés. Es muy importante mencionar que el problema anterior se trata desde dos puntos de vista: i) bajo el supuesto de normalidad y ii) bajo el supuesto de no normalidad. Los resultados resumidos en las siguientes secciones son trabajados para los casos univariado y multivariado e introducen al problema de cómo se comparan dos tratamientos en diseño experimental sobre la base que estas comparaciones son de interés relevante en la investigación.

2.2. Teoría basada en normalidad

Sea $x_{11}, x_{12}, \dots, x_{1n_1}$ una muestra aleatoria de variables independientes e idénticamente distribuidas $N(\mu_1, \sigma_1^2)$, asociada a una variable de interés, y sea $x_{21}, x_{22}, \dots, x_{2n_2}$ una segunda muestra aleatoria de variables aleatorias independientes e idénticamente distribuidas $N(\mu_2, \sigma_2^2)$, asociada a una segunda variable de interés. Si las dos muestras se asumen independientes, la hipótesis nula más frecuente planteada es la igualdad de medias, es decir,

$$H_0 : \mu_1 = \mu_2 \quad \text{frente a} \quad \begin{cases} H_a : \mu_1 \neq \mu_2 \\ H_a : \mu_1 > \mu_2 \\ H_a : \mu_1 < \mu_2. \end{cases}$$

En las decisiones que se tomen sobre la hipótesis anterior se deben tener en cuenta varias consideraciones, las cuales se estudian en las siguientes secciones.

2.2.1. Inferencia sobre diferencia de medias poblacionales cuando las varianzas son iguales

Supóngase que se tienen dos poblaciones independientes con medias desconocidas μ_1 y μ_2 , y varianzas conocidas σ_1^2 y σ_2^2 , respectivamente.

Para obtener el estadístico de prueba, se impone la restricción $\sigma_1^2 = \sigma_2^2$. Bajo esta condición de igualdad de varianzas la prueba de razón de verosimilitud es:

$$T_c = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}, \quad (2.1)$$

donde $\bar{x}_i = \frac{\sum_{j=1}^{n_i} x_{ij}}{n_i}$, $i = 1, 2$ y $s^2 = \frac{1}{n_1 + n_2 - 2} [(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2]$, con

$$s_i^2 = \frac{\sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2}{n_i - 1}, \quad i = 1, 2.$$

Bajo H_0 cierta, T_c se distribuye $t_{(n_1+n_2-2)}$. En el caso unilateral, se rechaza H_0 con un nivel α si $P[t_{(n_1+n_2-2)} > T_c] < \alpha$ y, en el caso bilateral, se rechaza si es menor que $\frac{\alpha}{2}$.

Para la construcción de los intervalos de confianza, se tiene la estadística pivotal (2.1). Siendo un intervalo de confianza $100(1 - \alpha)\%$ bilateral para $\mu_1 - \mu_2$,

$$IC(\mu_1 - \mu_2) = (\bar{x}_1 - \bar{x}_2) \pm t_{(\alpha/2, n_1+n_2-2)} s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}.$$

Ejemplo 2.1. En una investigación sobre tilapia, un zootecnista midió los pesos de 17 machos, los cuales pertenecían a dos tipos de especies diferentes: gregori (g) y santafe (s). El investigador cree que las tilapias macho pertenecientes a la especie gregori tienen en promedio un peso mayor que el peso promedio de las tilapias macho de la especie santafe. Se desea comprobar estadísticamente la afirmación del investigador. Los datos experimentales obtenidos por el investigador se presentan en la tabla 2.1.

Tabla 2.1: Pesos de las tilapias macho para las dos especies en estudio

Especie	Peso	Especie	Peso
s	15.16	s	30.86
g	28.99	s	14.00
g	16.95	s	38.72
g	29.61	s	23.29
g	35.61	s	17.00
g	20.69	s	35.40
g	17.39	s	19.32
g	29.94	s	29.88
g	22.79		

Suponga que $\sigma_s^2 = \sigma_g^2$ (este supuesto se prueba en el ejemplo 2.2) y que la variable peso se ajusta a una distribución normal. Con estos datos, se tiene

$$\begin{aligned}
 n_s &= 9; & \sum_{i=1}^9 x_{si} &= 223.63; & \bar{x}_s &= 24.85; & s_s &= 9.16 \\
 n_g &= 8; & \sum_{i=1}^8 x_{gi} &= 201.97; & \bar{x}_g &= 25.25; & s_g &= 6.76 \\
 s^2 &= \frac{1}{17-2} [8(9.16)^2 + 7(6.76)^2] = 66.08.
 \end{aligned}$$

En este caso se desea plantear la hipótesis $H_0 : \mu_s = \mu_g$ vs $H_a : \mu_g > \mu_s$. Por los supuestos planteados anteriormente y con base en la información obtenida, se encuentra que:

$$\begin{aligned}
 T_c &= \frac{(\bar{x}_g - \bar{x}_s) - (\mu_g - \mu_s)_{H_0}}{s_p \sqrt{\frac{1}{n_s} + \frac{1}{n_g}}} \\
 &= \frac{(25.25 - 24.85) - 0}{\sqrt{66.08 \left(\frac{1}{9} + \frac{1}{8} \right)}} = 0.101.
 \end{aligned}$$

Como $P(t_{15} > 0.101) = 0.46 > 0.05 = \alpha$, se concluye que no se puede rechazar H_0 , por lo cual no se puede aceptar la afirmación del investigador y estadísticamente se acepta que la especie no es un factor influyente en el peso de las tilapias machos.

Como se vio en el caso anterior de prueba de igualdad de medias, es necesario que se cumpla el supuesto $\sigma_1^2 = \sigma_2^2$, el cual debe juzgarse. En la sección 2.3 se presenta una prueba paramétrica en la cual se verifica dicho supuesto.

2.2.2. Inferencia sobre el cociente de varianzas

Supóngase que se tiene interés en dos poblacionales normales independientes, en los que las medias y varianzas de la población, μ_1 , σ_1^2 , μ_2 y σ_2^2 , son desconocidas. Se desea probar la hipótesis sobre la igualdad de las dos varianzas, $H_0 : \sigma_1^2 = \sigma_2^2$. Si se tiene información de dos muestras aleatorias, una de tamaño n_1 tomada de la población 1 y otra de tamaño n_2 tomada de la población 2, y s_1^2 y s_2^2 son las respectivas varianzas muestrales, la hipótesis bilateral

$$H_0 : \sigma_1^2 = \sigma_2^2 \text{ vs } H_a : \sigma_1^2 \neq \sigma_2^2$$

se puede contrastar mediante el estadístico de prueba (*Mood, 1974*)

$$F = \frac{s_1^2 \sigma_2^2}{s_2^2 \sigma_1^2} \sim F_{(n_1-1, n_2-1)}$$

y, además, la cola inferior de una distribución F se obtiene a partir de la expresión

$$F_{(1-\alpha, n_1-1, n_2-1)} = \frac{1}{F_{(\alpha, n_2-1, n_1-1)}}.$$

Por ejemplo, $F_{(0.95, 7, 9)} = \frac{1}{F_{(0.05, 9, 7)}} = \frac{1}{3.68} = 0.27$.

Con estos resultados pueden construirse los intervalos de confianza de $100(1 - \alpha) \%$ para σ_1^2 / σ_2^2 , nótese que:

$$P \left[F_{(n_1-1, n_2-1, 1-\alpha/2)} \leq F \leq F_{(n_1-1, n_2-1, \alpha/2)} \right] = 1 - \alpha$$

$$P \left[F_{(n_1-1, n_2-1, 1-\alpha/2)} \leq \frac{s_1^2 \sigma_2^2}{s_2^2 \sigma_1^2} \leq F_{(n_1-1, n_2-1, \alpha/2)} \right] = 1 - \alpha.$$

La anterior expresión puede escribirse como:

$$P \left[\frac{s_1^2}{s_2^2} \frac{1}{F_{(n_1-1, n_2-1, \alpha/2)}} \leq \frac{\sigma_1^2}{\sigma_2^2} \leq \frac{s_1^2}{s_2^2} F_{(n_2-1, n_1-1, \alpha/2)} \right] = 1 - \alpha.$$

Con el anterior intervalo puede también tomarse una decisión sobre la hipótesis nula $H_0 : \frac{\sigma_1^2}{\sigma_2^2} = 1$ vs la alternativa $H_a : \frac{\sigma_1^2}{\sigma_2^2} \neq 1$, rechazando la hipótesis nula si el valor 1 cae fuera de este intervalo de confianza.

Ejemplo 2.2. Para los datos del ejemplo 2.1 se desea comprobar si las dos varianzas en los pesos de las dos especies de tilapias son las mismas y, además, se quiere construir un intervalo de confianza del 95 % para la razón de esta variabilidad.

En este caso, la hipótesis de interés es $H_0 : \sigma_g^2 = \sigma_s^2$ vs $H_a : \sigma_g^2 \neq \sigma_s^2$. Por los supuestos planteados anteriormente y con base en la información obtenida, se encuentra que

$$F_C = \frac{s_s^2}{s_g^2} = \frac{83.91}{45.69} = 1.84.$$

Luego como $F_C = 1.84 < F_{(8,7,0.025)} = 4.90$, entonces no se rechaza H_0 (valor $p = 2 * p(F_C > 1.84) = 0.44$) y se concluye que hay evidencias estadísticas para no rechazar la igualdad de varianzas en los pesos en estas dos especies de tilapias. Además, con base en este resultado se puede realizar la prueba de igualdad de medias presentada en la sección 2.2.1.

Un intervalo de confianza del 95% para la razón de varianzas es:

$$\frac{83.91}{45.69} \left(\frac{1}{4.90} \right) \leq \frac{\sigma_s^2}{\sigma_g^2} \leq \frac{83.91}{45.69} (4.53)$$

$$0.37 \leq \frac{\sigma_1^2}{\sigma_2^2} \leq 8.32$$

Puesto que en el intervalo $(0.37, 8.32)$ se encuentra el 1, entonces hay evidencia estadística para no rechazar la hipótesis nula y, por lo tanto, las varianzas de las dos poblaciones son iguales.

2.2.3. Inferencia sobre diferencia de medias poblacionales cuando las varianzas son desiguales

Si el modelo es tal que x_{ij} , $i = 1, 2$, $j = 1, 2, \dots, n_i$ ($n_i > 0$) y, además, las muestras son independientes y normalmente distribuidas, es decir, $x_i \stackrel{iid}{\sim} N(\mu_i, \sigma_i^2)$, entonces se satisface $\bar{x}_1 - \bar{x}_2 \sim N\left(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right)$. Bajo las anteriores condiciones, la prueba de razón de verosimilitud para la hipótesis de igualdad de medias es:

$$T'_c = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}.$$

la cual tiene una distribución aproximada t , con grados de libertad aproximados (Satterthwaite 1946)

$$v = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^2}{\frac{\left(\frac{s_1^2}{n_1} \right)^2}{n_1 - 1} + \frac{\left(\frac{s_2^2}{n_2} \right)^2}{n_2 - 1}}.$$

En el caso unilateral, se rechaza H_0 con un nivel α si $P(t_{(v)} > T'_c) < \alpha$ y, en el caso bilateral, se rechaza si es menor de $\frac{\alpha}{2}$.

La construcción de un intervalo de confianza del $100(1-\alpha)\%$ se encuentra con la expresión

$$IC(\mu_1 - \mu_2) = (\bar{x}_1 - \bar{x}_2) \mp t_{(\frac{\alpha}{2}, v)} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}.$$

Ejemplo 2.3. *En un estudio que se lleva a cabo en el Departamento de Zoología del Instituto Politécnico y la Universidad Estatal de Virginia sobre el desarrollo de Ectromycorrhizal, una relación simbiótica entre las raíces de los árboles y un hongo en la que se transfieren minerales del hongo a los árboles y azúcares de los árboles a los hongos, se plantan en un invernadero 20 robles rojos con el hongo Pisolithus Tinctorius. Todos los arbolitos se plantan en el mismo tipo de suelo y reciben la misma cantidad de luz solar y agua. La mitad no recibe nitrógeno en el momento de plantarlos para servir como control y la otra mitad recibe 368ppm de nitrógeno en forma de NaNO_3 . Los pesos de los tallos, que se registran en gramos, al final de 140 días se presentan en la tabla 2.2.*

Tabla 2.2: Pesos de los tallos en gramos al final de 140 días

Sin nitrógeno	Con nitrógeno
0.32	0.26
0.53	0.43
0.28	0.47
0.37	0.49
0.47	0.52
0.43	0.75
0.36	0.79
0.42	0.86
0.38	0.62
0.43	0.46

Suponiendo que las poblaciones están distribuidas normalmente, se puede comprobar si las dos varianzas poblacionales entre los tallos que recibieron nitrógeno y los que no son iguales.

En este caso, la hipótesis de interés es $H_0 : \sigma_{SN}^2 = \sigma_{CN}^2$ vs $H_a : \sigma_{SN}^2 \neq \sigma_{CN}^2$. Por los supuestos planteados anteriormente y con base en la información obtenida, se encuentra que

$$F_C = \frac{s_{CN}^2}{s_{SN}^2} = \frac{0.0349}{0.0053} = 6.58.$$

Luego como $F_C = 6.58 > F_{(9,9,0.025)} = 4.03$, entonces se rechaza H_0 y se concluye que hay diferencias de varianzas en los pesos de los tallos que recibieron nitrógeno con respecto al control.

Además, se desea conocer si hay diferencias entre los pesos medios de los tallos que recibieron nitrógeno con respecto al control ($H_0 : \mu_{SN} = \mu_{CN}$). Para contrastar esta hipótesis, se hace del siguiente estadístico de prueba:

$$\begin{aligned} T'_c &= \frac{(\bar{x}_{SN} - \bar{x}_{CN}) - (\mu_{SN} - \mu_{CN})_{H_0}}{\sqrt{\frac{s_{SN}^2}{n_{SN}} + \frac{s_{CN}^2}{n_{CN}}}} = \frac{(0.399 - 0.565) - 0}{\sqrt{\frac{0.0053}{10} + \frac{0.0349}{10}}} \\ &= -2.619, \end{aligned}$$

como

$$v = \frac{\left(\frac{0.0053}{10} + \frac{0.0349}{10}\right)^2}{\frac{\left(\frac{0.0053}{10}\right)^2}{9} + \frac{\left(\frac{0.0349}{10}\right)^2}{9}} = 11.67,$$

entonces $v \approx 12$. De esta forma, como $2P(t_{12} < -2.619) = 0.022 < 0.05$, se rechaza $H_0 : \mu_{SN} = \mu_{CN}$, concluyendo así que hay diferencias entre los pesos al aplicar nitrógeno en los tallos respecto a cuando no se hace.

Por otro lado, aun sin el supuesto de normalidad, se encuentra que asintóticamente esta siguiendo la distribución normal, es decir, sea $\frac{n_1}{n_2} \rightarrow R$ cuando $n_1, n_2 \rightarrow \infty$. Entonces,

$$s^2 = \frac{n_1 - 1}{n_1 + n_2 - 2} s_1^2 + \frac{n_2 - 1}{n_1 + n_2 - 2} s_2^2 \xrightarrow{p} \frac{R}{1+R} \sigma_1^2 + \frac{1}{1+R} \sigma_2^2,$$

donde $s_i^2 = \frac{\sum_j (x_{ij} - \bar{x}_i)^2}{n_i - 1}$, $i = 1, 2$.

El resultado anterior tiene como soporte teórico el hecho de que una sucesión de variables aleatorias $\{X_n\}$ converge en probabilidad a la variable aleatoria X ($X_n \xrightarrow{p} X$) si $\lim_{n \rightarrow \infty} P[|X_n - X| < \epsilon] = 1$, para $\epsilon > 0$.

Asintóticamente, si se supone o no la normalidad, se tiene que

$$t = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{S \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} = \frac{\left[(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2) \right] \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} S \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

y, entonces,

$$t \sim N \left(0, \frac{1}{\frac{1}{1+R}\sigma_1^2 + \frac{1}{1+R}\sigma_2^2} \left(\frac{\sigma_1^2 + R\sigma_2^2}{1+R} \right) \right).$$

Observación 2.1. La varianza asintótica de t puede ser de la forma $Var(t) = \frac{\theta + R}{R\theta + 1}$, con $\theta = \frac{\sigma_1^2}{\sigma_2^2}$. Nótese que si $R = 1$ y $n_1 = n_2$, entonces, $Var(t) = 1$.

Por lo tanto, cuando las muestras son de igual tamaño, la desigualdad de la varianza no afecta la inferencia asintótica. Si las muestras son ligeramente iguales, la prueba t puede tolerar gran discrepancia entre las varianzas.

Si $\theta = 2$ y $R = 2$, la varianza de la primera población es dos veces más grande que la varianza de la segunda, pero también la muestra de la primera población es dos veces mayor que la muestra de la segunda población. En este caso, $Var(t) = 0.8$, y la desviación estándar asintótica es 0.9 en vez de 1. Por lo tanto, el efecto del valor de la probabilidad P no es grande.

Otra situación a tener en cuenta es que $\sigma_1^2 \gg \sigma_2^2$ ($\gg$ mucho mayor que) y $n_1 \ll n_2$, entonces el estadístico t es aproximadamente

$$t \approx \frac{\bar{x}_1 - \mu_1}{\left[\frac{n_1}{n_1 + n_2} s_1^2 + \sigma_2^2 \right]^{1/2} \left[\frac{1}{n_1} \right]^{1/2}} \quad (2.2)$$

porque $\bar{x}_2 - \mu_2 = 0$, $s_2^2 = \sigma_2^2$, $\frac{n_2}{n_1 + n_2} \cong 1$ y $\frac{1}{n_2} \cong 0$.

Si $\frac{n_1}{n_1 + n_2} s_1^2$ es relativamente menor que σ_2^2 , la razón (2.2) converge a una distribución normal con varianza $\frac{\sigma_1^2}{\sigma_2^2}$ en vez de 1 (Miller 1986). Si $\frac{n_1 s_1^2}{n_1 + n_2}$ es relativamente grande con respecto a σ_2^2 , entonces (2.2) se distribuye como una t con $n_1 - 1$ grados de libertad multiplicado por $\frac{\sqrt{n_1 + n_2}}{n_1}$; en cualquier caso, la variabilidad es mayor que en el caso donde se tiene la hipótesis con $n_1 + n_2 - 2$.

2.3. Efecto de no normalidad

Siguiendo con el supuesto de igualdad de varianzas (es decir, $\sigma_1^2 = \sigma_2^2$), si además se tiene que $I_1(x_1)$, $I_2(x_1)$, $I_1(x_2)$ y $I_2(x_2)$ son el sesgo y la curtosis de las dos poblaciones,

$$\begin{aligned} I_1(x_1) &= \frac{E(x_1 - \mu_1)^3}{\sigma_1^3} & I_1(x_2) &= \frac{E(x_2 - \mu_2)^3}{\sigma_2^3} \\ I_2(x_1) &= \frac{E(x_1 - \mu_1)^4}{\sigma_1^4} - 3 & I_2(x_2) &= \frac{E(x_2 - \mu_2)^4}{\sigma_2^4} - 3. \end{aligned}$$

Observación 2.2. Sobre normalidad se satisface: $I_1(x_1) = I_2(x_1) = 0$, $I_1(x_2) = I_2(x_2) = 0$.

Observación 2.3. Una distribución con sesgo a la derecha $I_1(x)$ debe ser positivo; así, por ejemplo, si se tiene la distribución exponencial $f(x) = \lambda e^{-\lambda x}$, con $\lambda > 0$ y $x > 0$, se tiene que $I_1(x) = 2$. Entre tanto, si la distribución está sesgada a la izquierda, $I_1(x)$ debe ser negativo.

Observación 2.4. Cuando las colas de la distribución tienen más masa que la normal, la curtosis $I_2(x)$ debe ser positiva. Así, por ejemplo, en el caso de la distribución doble exponencial $f(x) = \frac{\lambda}{2} \exp(-\lambda |x|)$, con $\lambda > 0$ y $x \in R$, se tiene $I_2(x) = 3$.

También de la distribución t -student se sigue

$$f(t) = \frac{\Gamma[(k+1)/2]}{\Gamma(k/2)} \frac{1}{\sqrt{kt}} \frac{1}{(1+t^2/k)^{\frac{k+1}{2}}}, \quad k > 0$$

y se obtiene el coeficiente de curtosis $I_2(t) = \frac{6}{(k-4)}$, para $k > 4$. La historia de la no normalidad es de fácil entendimiento al observar los tres primeros momentos de la expansión de la distribución t (Miller 1986).

$$E(t) \cong \frac{1}{v_1^{\frac{1}{2}}} \left[-\frac{1}{2v_2} (I_1(x_1) - I_1(x_2)) \right] \quad (2.3)$$

$$\begin{aligned} Var(t) \cong \frac{1}{v_1} \left\{ \left(1 + \frac{2}{v_2} \right) v_1 + \frac{7}{4} \left(I_1(x_1) - I_1(x_2) \right)^2 \frac{1}{v_2^2} \right. \\ \left. + \left(I_2(x_1) - I_2(x_2) \right) (n_1 - n_2) \frac{v_1}{v_2^2} \right\} \quad (2.4) \end{aligned}$$

$$E[t - E(t)]^3 \cong \frac{1}{v_1^{\frac{3}{2}}} \left\{ \frac{I_1(x_1)}{n_1^2} - \frac{I_1(x_2)}{n_2^2} - 3 \left[I_1(x_1) - I_1(x_2) \right] \frac{v_1}{v_2} \right\}, \quad (2.5)$$

donde $v_1 = \frac{1}{n_1} + \frac{1}{n_2}$ y $v_2 = n_1 + n_2 - 2$.

En muchas situaciones experimentales se asume que $I_1(x_1) \approx I_1(x_2)$ y también que $I_2(x_1) \approx I_2(x_2)$. Si este fuere el caso, la expresión (2.4) se reduce a

$$Var(t) = \frac{1}{v_1} \left[\left(1 + \frac{2}{v_1} \right) v_1 \right].$$

Se muestra entonces que el parámetro de curtosis tiene un efecto pequeño en la distribución del estadístico t y, cuando las muestras son aproximadamente iguales (es decir, $n_1 \approx n_2$), el parámetro de sesgo cancela cualquier otra aproximación. Por lo tanto, para muestras de igual tamaño el estadístico t es más robusto para el caso de dos muestras que para el caso de una muestra. Esto garantiza para el investigador que en caso balanceado todo sea estimable.

2.3.1. Pruebas no paramétricas

La prueba más conocida para la comparación de dos poblaciones, después de la prueba t , es la prueba de rango de Wilcoxon (1945). Su eficiencia asintótica comparada con la t es mayor y más eficiente que la t para distribuciones con colas pesadas. La estadística de Wilcoxon se obtiene de dos formas: la primera es un método que depende de los rangos. Combina las dos muestras en un conjunto de $n_1 + n_2$ observaciones. Posteriormente, se ordenan las observaciones de la más pequeña a la más grande ($x_{(1)} < x_{(2)} < \dots < x_{(n_1+n_2)}$) y se asigna el rango i a la i -ésima observación más grande. Sea R_1 la suma de los rangos asociada a las observaciones de la primera muestra y, similarmente, sea R_2 la suma de los rangos para la segunda muestra. La estadística de Wilcoxon es R_1 o R_2 , o también $R_1 - R_2$ cuando $n_1 = n_2$, de ahí se sigue que

$$R_1 + R_2 = \frac{(n_1 + n_2)(n_1 + n_2 + 1)}{2} \quad (2.6)$$

Alguna de las anteriores estadísticas contiene toda la información sobre la suma de rangos.

La segunda forma propuesta por Mann y Whitney (1947) define la estadística de Wilcoxon como

$$U = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} I(x_{1i} > x_{2j}), \quad (2.7)$$

$$\text{donde } I(x_{1i} > x_{2j}) = \begin{cases} 1 & \text{si } x_{1i} > x_{2j} \\ 0 & \text{si } x_{1i} < x_{2j} \end{cases} \quad i \neq j.$$

El método de conteo (2.7) se puede asociar con el procedimiento de los rangos de la siguiente forma:

$$R_1 = \frac{n_1(n_1 + 1)}{2} + U.$$

El anterior resultado es cierto, ya que si todos los x_{1i} preceden a todos los x_{2j} , la suma de los rangos R_1 es $\frac{n_1(n_1+1)}{2}$ y U debe ser cero. Cada vez que un x_{2j} sea menor de un x_{1i} , este incrementa el rango de x_{1i} en uno y, a la vez, incrementa la suma de U en uno. En caso de empates, se asigna el rango promedio a cada una de las observaciones empatadas.

En este caso, la estadística U juzga la hipótesis H_0 : las distribuciones de frecuencias relativas de las dos poblaciones son idénticas. En el caso de la alternativa a dos colas, se rechaza H_0 si $P(U \geq U_0) < \frac{\alpha}{2}$ y, cuando solo se tiene una cola, se rechaza H_0 si $P(U \geq U_0) < \alpha$. En el apéndice, tabla A.5, se encuentra el nivel de significación observado para la prueba o el valor P .

Ejemplo 2.4. *Basados en el ejemplo 2.1, se obtiene la tabla 2.3 ordenando todos los datos y colocándolos de nuevo en la muestra correspondiente.*

Tabla 2.3: Rangos asociados con los datos del ejemplo 2.1

Línea	Peso	Rango
s	15.16	2
g	28.99	10
g	16.95	3
g	29.61	11
g	35.61	16
g	20.69	7
g	17.39	5
g	29.94	13
g	22.79	8
s	30.86	14
s	14.00	1
s	38.72	17
s	23.29	9
s	17.00	4
s	35.40	15
s	19.32	6
s	29.88	12

En este caso, $n_s = 9$, $n_g = 8$, $R_s = 80$ y $R_g = 73$, luego, aplicando (2.6), se tiene

$$R_s + R_g = \frac{(9+8)(9+8+1)}{2} = 153.$$

Aplicando la prueba de Mann y Whitney (1947), para la hipótesis H_0 : las distribuciones de frecuencias relativas al peso de las dos clases de tilapias son idénticas vs H_a : la distribución de frecuencias relativas de los pesos de las tilapias gregori está desplazada a la derecha de la distribución de los pesos de las tilapias santafe, se encuentra:

$$\begin{aligned} U &= \sum_{i=1}^9 \sum_{j=1}^8 I(x_{1i} > x_{2j}) \\ &= 8(0) + 7(1) + 1(0) + 8(0) + 8(1) + 4(1) + 4(0) + 1(1) + 7(0) \\ &\quad + 7(1) + 0(1) + 2(1) + 6(0) + 6(1) + 2(0) = 35. \end{aligned}$$

Con la finalidad de tomar una decisión con respecto a H_0 , al utilizar un nivel de significación de 5% y haciendo uso de la tabla A.5 del apéndice, se obtiene que

$$P(U \geq 35) = 0.5558 > 0.05.$$

Por lo cual no se rechaza H_0 , confirmando esto el resultado obtenido a través de las pruebas paramétricas.

Asintóticamente, U (y R_1 o R_2) tiene una distribución normal. Bajo la hipótesis nula de no existencia de diferencia entre los parámetros de las poblaciones, cuando no hay empates, su media y varianza exacta son

$$\begin{aligned} E(U) &= \frac{n_1 n_2}{2}, \\ Var(U) &= \frac{n_1 n_2 (n+1)}{12}, \end{aligned}$$

donde $n = n_1 + n_2$. La aproximación para muestras grandes es buena cuando n_1 y n_2 son al menos de tamaño 10.

Cuando se presenta empate, la media exacta y varianza de U , condicionando el patrón de empates, puede ser calculada. La media condicional de U es $\frac{n_1 n_2}{2}$. Para obtener la varianza, sea $z_1, \dots, z_m$ los distintos valores en la muestra combinada de x_{1i} y x_{2j} , y sea $t_1, \dots, t_m$ el número de observaciones que iguala cada uno de estos valores. En el caso de una observación que no sea igual a otra, $t_i = 1$.

Entonces, la varianza condicional de U es (Miller 1986)

$$\begin{aligned} Var(U/t_1, \dots, t_m) &= \frac{n_1 n_2}{12} \left[n + 1 - \frac{\sum_{i=1}^m (t_i^3 - t_i)}{n(n-1)} \right] \\ &= \frac{n_1 n_2 (n+1)}{12} \left[1 - \frac{\sum_{i=1}^m (t_i^3 - t_i)}{n^3 - n} \right], \end{aligned}$$

lo cual quiere decir que el factor de corrección por empate es $1 - \frac{\sum (t_i^3 - t_i)}{n^3 - n}$.

Observación 2.5. A diferencia de la prueba del rango signado de Wilcoxon para una muestra, no se asume simetría de las distribuciones para el caso de dos muestras.

Observación 2.6. El estimador para la diferencia en localización de las dos poblaciones asociadas con la estadística del rango de Wilcoxon es el estimador de Hodges y Lehmann (1963). Este estimador denotado por $\hat{\Delta}_{HL}$ es la mediana de la colección de los $n_1 n_2$ valores $(x_{1i} - x_{2j}, i = 1, \dots, n_1, j = 1, \dots, n_2)$.

Un intervalo de confianza para la verdadera diferencia Δ en localización de las dos poblaciones puede ser construida con base en la estadística de Wilcoxon, suponiéndose que las formas de las dos distribuciones son la misma excepto por su localización. De esta forma, Δ es la diferencia entre las medias o medianas. En la figura propuesta por Mann-Witney, el intervalo de confianza se basa en todos los valores de Δ para los cuales $U(\Delta) = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} I(x_{1i} - \Delta > x_{2j})$ no difiere significativamente de la media $\frac{n_1 n_2}{2}$. Esto es numéricamente tedioso de construir, pero el método gráfico simplifica los cálculos. En este caso, se deben graficar los $n_1 n_2$ puntos $(x_{1i}, x_{2j}), i = 1, \dots, n_1, j = 1, \dots, n_2$. Sea $U_{\frac{\alpha}{2}}$ el valor crítico inferior para la estadística U basada en $n_1 n_2$ observaciones, es decir, $U_{\frac{\alpha}{2}}$ es el entero más grande tal que $P(U \leq U_{\frac{\alpha}{2}}/H_0) \leq \frac{\alpha}{2}$. En muestras grandes

$$U_{\frac{\alpha}{2}} \cong \left[\frac{n_1 n_2}{2} - \frac{1}{2} \right] - Z_{\frac{\alpha}{2}} \left[\frac{n_1 n_2 (n_1 + n_2 - 1)}{12} \right]^{\frac{1}{2}},$$

donde $\frac{1}{2}$ es una corrección por continuidad y $Z_{\frac{\alpha}{2}}$ es el percentil $100(\frac{\alpha}{2})\%$ de la distribución normal. Para obtener una región de confianza se debe trazar una recta de 45° en el punto $\hat{\Delta}_{HL}$, luego encontrar el punto de intersección entre la recta trazada y el eje X_1 , enseguida se deben sumar y restar $U_{\frac{\alpha}{2}}$ unidades al cruce encontrado y llamar a estos puntos Δ_I y Δ_S . Se deben trazar las dos rectas con una inclinación de 45° a partir de los puntos Δ_I y

Δ_S . El intervalo entre Δ_I y Δ_S es el intervalo de confianza para Δ . El anterior procedimiento se ilustra a través del siguiente ejemplo.

Ejemplo 2.5. Retomando el ejemplo 2.1 y utilizando un nivel de significación de 5%, se obtiene

$$U_{\frac{\alpha}{2}} \cong \frac{8 \times 9}{2} - \frac{1}{2} - 1.96 \left(\frac{9 \times 8 \times 18}{12} \right)^{\frac{1}{2}} \\ \cong 15.13.$$

Para este caso $\hat{\Delta}_{HL} = (23.29, 25.89)$ y, realizando los procedimientos descritos anteriormente, se obtiene la gráfica 2.1, en la cual se ilustra el intervalo de confianza para Δ .




Figura 2.1: Intervalo de confianza para Δ .

2.3.2. Estimación robusta

La estimación robusta en el problema de dos muestras se limita en este libro a la *trimedia*. En este caso se asume que la función de distribución acumulada para cada población es simétrica alrededor de su mediana. Si el anterior supuesto no se cumple, se puede inicialmente transformar los datos para lograr la simetría. Específicamente, sea δ la fracción *trimedia*, donde se asume que δn_1 y δn_2 son enteros. La *trimedia* se define como (Miller 1986)

$$\bar{x}_{Ti} = \frac{1}{(1 - 2\delta)n_i} \sum_{j=\delta n_i+1}^{n_i-\delta n_i} x_{i(j)}, \quad i = 1, 2,$$

donde $x_{i(1)} \leq x_{i(2)} \leq \dots \leq x_{i(n_i)}$ son los estadísticos de orden para la i -ésima muestra y sea

$$s_{W_i}^2 = \frac{1}{(1-2\delta)^2(n_i-1)} \left[\delta n_i (x_{i(\delta n_i+1)} - \bar{x}_{Wi})^2 + \sum_{j=\delta n_i+1}^{n_i-\delta n_i} (x_{i(j)} - \bar{x}_{Wi})^2 + \delta n_i (x_{i(n_i-\delta n_i)} - \bar{x}_{Wi})^2 \right],$$

$$\text{donde } \bar{x}_{Wi} = \frac{1}{n_i} \left[\delta n_i x_{i(\delta n_i+1)} + \sum_{j=\delta n_i+1}^{n_i-\delta n_i} x_{i(j)} + \delta n_i x_{i(n_i-\delta n_i)} \right].$$

Luego la varianza muestral conjunta es:

$$s_W^2 = \frac{(n_1-1)s_{W_1}^2 + (n_2-1)s_{W_2}^2}{n_1 + n_2 - 2}. \quad (2.8)$$

Así, la estadística de la trimedia t apropiada para juzgar $H_0 : F_1 = F_2$ es:

$$t = \frac{\bar{x}_{T_1} - \bar{x}_{T_2}}{s_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}. \quad (2.9)$$

Yuen y Dixon (1973) probaron que la estadística (2.9) se distribuye como una distribución t , con $(1-2\delta)(n_1+n_2)-2$ grados de libertad. La varianza conjunta (2.8) y la estadística (2.9) se basan en el supuesto que las funciones de distribución conjunta F_1 y F_2 son idénticas y simétricas, excepto por un parámetro de localización. Nótese que la estadística (2.9) es análoga al caso paramétrico asumiendo $\sigma_1^2 = \sigma_2^2$.

Ejemplo 2.6. Para la información del ejemplo 2.1, se propone la prueba $H_0 : \mu_s = \mu_g$ vs $H_a : \mu_g > \mu_s$, pero en este caso se hará uso de una estadística robusta. Con base en la información de la tabla 2.1, se obtiene para las tilapias santafe (s)

$$\bar{x}_s = \frac{1}{(1-2\delta)} \sum_{j=\delta 9+1}^{9-\delta 9} x_{s(j)}.$$

Haciendo $\delta = 0$ y, además, reordenando los datos: $14 < 15.16 < 17 < 19.32 < 23.29 < 29.88 < 30.86 < 35.4 < 38.72$, se encuentra

$$\begin{aligned} \bar{x}_s &= \frac{1}{9} \sum_{j=1}^9 x_{s(j)} \\ &= \frac{1}{9} (14 + 15.16 + 17 + 19.32 + 23.29 + 29.88 + 30.86 + 35.4 + 38.72) \\ &= 24.847. \end{aligned}$$

y, para las tilapias gregori (g), reordenando los datos de esta muestra: $16.95 < 17.39 < 20.69 < 22.79 < 28.99 < 29.61 < 29.94 < 35.61$, entonces

$$\bar{x}_g = \frac{1}{4} \sum_{j=2}^7 x_{g(j)} = 25.246.$$

Además, $s_s^2 = 83.92$ y $s_g^2 = 45.69$. Luego la varianza muestral conjunta es $s^2 = 66.08$ y el estadístico de prueba es $T_c = 0.101$.

Como $t_{(0.05, 15)} = 1.753 > T_c = 0.101$, entonces no se rechaza H_0 , con lo cual se obtiene un resultado equivalente en la decisión al presentado cuando se supuso distribución normal para las variables aleatorias y $\sigma_s^2 = \sigma_g^2$.

2.4. Prueba estadística multivariada para la comparación de dos medias: T^2 -Hotelling

Sea la hipótesis de interés $H_0 : \mu_1 = \mu_2$, en la cual se desea evaluar la igualdad de medias multivariadas, entonces se obtiene el siguiente estadístico de prueba

$$F = t^2 = \frac{(\bar{x}_1 - \bar{x}_2)^2}{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2} \left(\frac{1}{n_1} + \frac{1}{n_2} \right)} = \frac{n_1 n_2}{n_1 + n_2} (\bar{x}_1 - \bar{x}_2)^t s^{-1} (\bar{x}_1 - \bar{x}_2),$$

donde $s = \frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}$. Cuando la hipótesis $H_0 : \mu_1 = \mu_2$ de igualdad de medias es cierta, entonces $F \sim F_{(1, n_1+n_2-2)}$.

Suponiendo ahora que las dos muestras aleatorias independientes de tamaño n_1 y n_2 proceden de poblaciones normales multivariadas, esto es, $\mathbf{X}_1 \sim N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$ y $\mathbf{X}_2 \sim N_p(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$.

Al asumir que $\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2 = \boldsymbol{\Sigma}$ y aunarlos con los resultados de la muestra se obtienen las estadísticas

$$\bar{\mathbf{X}}_1 = \begin{pmatrix} \bar{X}_{11} \\ \vdots \\ \bar{X}_{p1} \end{pmatrix}, \quad \bar{\mathbf{X}}_2 = \begin{pmatrix} \bar{X}_{12} \\ \vdots \\ \bar{X}_{p2} \end{pmatrix}, \quad \mathbf{S}_1, \quad \mathbf{S}_2 \quad \text{y} \quad \mathbf{S},$$

donde $\mathbf{S}_1$ es la matriz de covarianzas de la primera muestra, $\mathbf{S}_2$ es la matriz de covarianzas de la segunda muestra y $\mathbf{S} = \frac{(n_1-1)\mathbf{S}_1 + (n_2-1)\mathbf{S}_2}{n_1+n_2-2}$ la matriz combinada.

Además, se cumple que

$$E(\bar{X}_1) = \mu_1 \quad E(\bar{X}_2) = \mu_2.$$

El estadístico de prueba para la hipótesis $H_0 : \mu_1 = \mu_2$, suponiendo igual matriz de covarianzas, es:

$$T_c^2 = \frac{n_1 n_2}{n_1 + n_2} (\bar{X}_1 - \bar{X}_2)^t S^{-1} (\bar{X}_1 - \bar{X}_2).$$

Cuando la hipótesis es cierta, el estadístico es

$$\frac{(n_1 + n_2 - 2) - p + 1}{(n_1 + n_2 - 2)p} T^2 \sim F_{(p, (n_1 + n_2 - 2) - p + 1)}.$$

Equivalentemente, el percentil en la distribución de T^2 está dado por

$$T_{1-\alpha}^2 = \frac{(n_1 + n_2 - 2)p}{(n_1 + n_2 - 2) - p + 1} F_{(1-\alpha, p, (n_1 + n_2 - 2) - p + 1)}.$$

La decisión con un nivel de significación α es rechazar H_0 si $T_c^2 > T_{1-\alpha}^2$.

Ejemplo 2.7. En un estudio realizado en la Universidad Nacional de Colombia sobre la influencia de la osmodeshidratación y la refrigeración en la estabilidad del pimentón rojo se midió el °Brix y PH de este proceso al utilizar dos agentes osmodeshidrantes: sacarosa cristalina (SC) y sal sólida (SS). Se tiene interés en evaluar si los dos agentes osmodeshidrantes presentan estadísticamente promedios equivalentes. Los datos obtenidos fueron los siguientes:

Agente osmodeshidratante	°Brix (x_1)	PH (x_2)
Sacarosa cristalina	17.0	5.05
Sacarosa cristalina	17.5	5.07
Sacarosa cristalina	17.2	5.02
Sacarosa cristalina	21.0	5.15
Sacarosa cristalina	20.5	5.17
Sacarosa cristalina	20.7	5.12
Sal sólida	30.0	4.21
Sal sólida	29.0	4.24
Sal sólida	29.5	4.18
Sal sólida	31.0	4.13
Sal sólida	31.0	4.16
Sal sólida	30.0	4.18

Se supone, además, que las dos muestras aleatorias independientes proceden de poblaciones normales multivariadas. Se desea entonces tomar una decisión sobre la hipótesis

$$\begin{array}{ccc}
H_0 : \mu_{sc} = \mu_{ss} & & H_0 : \begin{pmatrix} \mu_{scBrix} \\ \mu_{scPH} \end{pmatrix} = \begin{pmatrix} \mu_{ssBrix} \\ \mu_{ssPH} \end{pmatrix} \\
\text{vs} & \text{O} & \text{vs} \\
H_a : \mu_{sc} \neq \mu_{ss} & & H_a : \begin{pmatrix} \mu_{scBrix} \\ \mu_{scPH} \end{pmatrix} \neq \begin{pmatrix} \mu_{ssBrix} \\ \mu_{ssPH} \end{pmatrix}.
\end{array}$$

Con base en la información observada, se tiene

Sacarosa cristalina	Sal sólida
$\sum Brix_i = 113.9$	$\sum Brix_j = 180.5$
$\sum PH_i = 30.58$	$\sum PH_j = 24.1$
$\sum (Brix_i)^2 = 2180.83$	$\sum (Brix_j)^2 = 5433.25$
$\sum (PH_i)^2 = 155.87$	$\sum (PH_j)^2 = 105.01$
$\sum (Brix_i)(PH_i) = 581.04$	$\sum (Brix_j)(PH_j) = 754.96$

$$\begin{aligned}
\bar{X}_{sc} &= \begin{pmatrix} 18.98 \\ 5.09 \end{pmatrix}, \bar{X}_{ss} = \begin{pmatrix} 30.08 \\ 4.18 \end{pmatrix}, d = \bar{X}_{sc} - \bar{X}_{ss} = \begin{pmatrix} -11.1 \\ 0.91 \end{pmatrix}, (n_{sc} - 1)\mathbf{S}_{sc} = \\
&\begin{pmatrix} 18.628 & 0.528 \\ 0.528 & 0.017 \end{pmatrix} y (n_{ss} - 1)\mathbf{S}_{ss} = \begin{pmatrix} 3.208 & -0.132 \\ -0.132 & 0.007 \end{pmatrix}.
\end{aligned}$$

La matriz inversa de covarianzas combinada se obtiene a partir de la expresión

$$\begin{aligned}
L &= (n_{sc} + n_{ss} - 2)\mathbf{S} = (n_{sc} - 1)\mathbf{S}_{sc} + (n_{ss} - 1)\mathbf{S}_{ss} \\
&= \begin{pmatrix} 21.84 & 0.40 \\ 0.40 & 0.02 \end{pmatrix}.
\end{aligned}$$

Despejando $\mathbf{S}$ y luego invirtiendo esta matriz, se encuentra

$$\mathbf{S}^{-1} = (n_{sc} + n_{ss} - 2) \begin{pmatrix} 0.06 & -1.03 \\ -1.03 & 56.54 \end{pmatrix}.$$

Con estos resultados, se encuentra el estadístico T_c^2 , dado por

$$\begin{aligned}
T_c^2 &= \frac{n_{sc}n_{ss}}{n_{sc} + n_{ss}} d^t \mathbf{S}^{-1} d \\
&= \frac{36}{12} \begin{pmatrix} -11.1 & 0.91 \end{pmatrix} \begin{pmatrix} 0.64 & -10.25 \\ -10.25 & 565.44 \end{pmatrix} \begin{pmatrix} -11.10 \\ 0.91 \end{pmatrix} \\
&= \begin{pmatrix} -49.54 & 1890.77 \end{pmatrix} \begin{pmatrix} -11.10 \\ 0.91 \end{pmatrix} = 2276.77.
\end{aligned}$$

Como $T_{0.95}^2 = \frac{20}{9} F_{(0.95, 2, 9)} = \frac{20}{9} (4.26) = 9.46 < T_c^2 = 2276.77$, entonces se tiene evidencia estadística para rechazar H_0 , y se concluye que existen diferencias entre los promedios del °Brix y PH en los dos agentes osmodeshidratantes.

2.5. Comparaciones pareadas, estudio de un prueba simultáneo para comparar medias y varianzas

Bradley y Blackwood (1989) desarrollaron una prueba estadística para la comparación simultánea de medias y varianzas en el caso de comparaciones pareadas asumiendo muestras aleatorias procedentes de poblaciones normales. En el desarrollo de la prueba se generalizan algunas ideas de la prueba de Pitman.

Si $\mathbf{X} = [X_1 \ X_2]$ es un vector aleatorio tal que

$$\mathbf{X} \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \quad \boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}, \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{pmatrix},$$

sea

$$D = X_1 - X_2, \quad S = X_1 + X_2.$$

$$\text{Cov}(D, S) = \text{Var}(X_1) + \text{Cov}(X_1, X_2) - \text{Cov}(X_1, X_2) - \text{Var}(X_2) = \sigma_1^2 - \sigma_2^2$$

$$\text{Var}(S) = \sigma_1^2 + \sigma_2^2 + 2\rho_{12}\sigma_1\sigma_2 = \sigma_S^2 \quad (2.10)$$

$$\text{Var}(D) = \sigma_1^2 + \sigma_2^2 - 2\rho_{12}\sigma_1\sigma_2 = \sigma_D^2. \quad (2.11)$$

Además, el coeficiente de correlación entre las variables aleatorias D y S es $\rho_{DS} = \frac{\sigma_1^2 - \sigma_2^2}{\sigma_D \sigma_S}$. Si se desea juzgar la hipótesis $H_0 : \sigma_1^2 = \sigma_2^2$, esta hipótesis es equivalente a $H_0 : \rho_{DS} = 0$. Al considerar que $\sigma_D^2 = 0$ de (2.11), se sigue que

$$\rho_{12} = \frac{\left(\frac{\sigma_1}{\sigma_2} + \frac{\sigma_2}{\sigma_1}\right)}{2}, \quad \text{teniendo en cuenta que } -1 < \rho_{12} < 1.$$

El mínimo valor que toma este coeficiente de correlación es cuando $\sigma_1 = \sigma_2$, es decir que $\rho_{12} = 1$. En forma semejante, si $\sigma_S^2 = 0$ de (2.10), se tiene que cuando $\sigma_1^2 = \sigma_2^2$ entonces $\rho_{12} = -1$.

Sea ahora

$$E(D/S) = (\mu_1 - \mu_2) + \rho_{SD}(\sigma_D/\sigma_S)(S - (\mu_1 + \mu_2)), \quad (2.12)$$

y recordando que la distribución condicional sobre normalidad es (Díaz 2002):

$$Y_2/Y_1 \sim N\left([\mu_2 + V_{21}V_{11}^{-1}(Y_1 - \mu_1)], [V_{22} - V_{21}V_{11}^{-1}V_{12}]\right).$$

De esta forma, (2.12) se puede expresar como

$$E(D/S) = (\mu_1 - \mu_2) + \frac{(\sigma_1^2 - \sigma_2^2)}{\sigma_S^2} [S - (\mu_1 + \mu_2)] = \beta_0 + \beta_1 S \quad (2.13)$$

siendo $\beta_0 = \frac{(\sigma_1^2 - \sigma_2^2)}{\sigma_S^2}(\mu_1 + \mu_2) + (\mu_1 - \mu_2)$ y $\beta_1 = \frac{(\sigma_1^2 - \sigma_2^2)}{\sigma_S^2}$.

Sea $\sigma_1^2 = \sigma_2^2$ y $\mu_1 = \mu_2$ si y solo si $\beta_0 = \beta_1 = 0$, con lo cual se construye la prueba simultánea de igualdad de medias y varianzas. El estadístico de la prueba es:

$$F = \frac{(\sum d_t^2 - SCE)/2}{SCE/(n-2)} \sim F_{(2, n-2)}, \quad (2.14)$$

donde SCE es la suma de cuadrados del residuo en la regresión D sobre S y

$$\sum_{t=1}^n d_t^2 = \sum_{t=1}^n (X_{tD} - X_{tS})^2$$

es la suma de cuadrados de las diferencias entre dos muestras pareadas.

Ejemplo 2.8. *Los siguientes datos corresponden a un estudio realizado en la Universidad Nacional de Colombia sobre la evaluación de una dieta sobre el peso de peces pirarucu (Arapaima Gigas) en su etapa de alexinaje. Para evaluar este efecto, se pesaron los peces en dos ocasiones antes de comenzar la dieta y después de la misma. Los resultados se presentan en la tabla 2.4.*

Tabla 2.4: Ganancia de peso en una dieta con harina de pescado

Antes	Después	$x_{tD} - x_{tA}$
56	142.0	86.0
31	101.0	70.0
29	90.0	61.0
27	88.2	61.2
25	81.3	56.3
23	77.0	54.0
21	74.0	53.0
21	54.4	33.4
18	51.2	33.2

Si se supone que las anteriores observaciones provienen de muestras aleatorias procedentes de poblaciones normales y si se desea probar que la dieta tiene algún efecto en el peso del pirarucu, entonces

$$H_0 : \mu_{Antes} = \mu_{Después} \text{ y } \sigma_{Antes}^2 = \sigma_{Después}^2$$

vs

$$H_a : \mu_{Antes} \neq \mu_{Después} \text{ y } \sigma_{Antes}^2 \neq \sigma_{Después}^2$$

Utilizando la estadística (2.14), se encuentra que

$$F_c = \frac{\frac{\sum_{t=1}^9 d_t^2 - SCE}{2}}{\frac{SCE}{n-2}},$$

donde $\sum_{t=1}^9 d_t^2 = \sum_{t=1}^9 (x_{t_D} - x_{t_A})^2 = 30874.93$ y $SCE = 547.77$.

Por lo tanto,

$$F_c = \frac{\frac{30874.93 - 547.77}{2}}{\frac{547.77}{7}} = \frac{15163.58}{78.25} = 193.78.$$

Como $F_c = 193.78 > F_{(2,7,0.05)} = 4.73$, se rechaza H_0 y se concluye que la dieta a base de harina de pescado es efectiva para aumentar el peso de estos, a la vez que no se rechaza la igualdad de varianzas poblacionales.

2.5.1. Prueba de rangos con signo de Wilcoxon para comparaciones pareadas

Para realizar la prueba de rangos con signo de Wilcoxon, se calculan las diferencias $(x_{i1} - x_{i2})$ para cada uno de los n pares. Se eliminan las diferencias iguales a cero y se reduce, conforme a ello, el número de pares. Se ordenan los valores absolutos de las diferencias, asignado el rango 1 al más pequeño, el rango 2 al siguiente, etc., luego se calcula la suma de los rangos para las diferencias negativas, R^- , y, también, para las diferencias positivas, R^+ . En este caso, la hipótesis nula es H_0 : las dos distribuciones de frecuencias relativas en las dos poblaciones son idénticas. Para tomar una decisión respecto a la anterior hipótesis, se toma $R = \min\{R^-, R^+\}$. En el caso de dos colas. Se rechaza H_0 si $R < R_0$, donde R_0 es el valor crítico dado en la tabla A.6 del apéndice.

Cuando la alterna es unilateral, se rechaza H_0 si $R^- < R_0$ o $R^+ > R_0$, según sea la alterna.

Ejemplo 2.9. Retomando el ejemplo 2.8, al hacer uso del estadístico de Wilcoxon para probar H_0 : las dos distribuciones poblacionales del peso antes y después son idénticas vs H_a : la distribución del peso después está desplazada a la derecha de la distribución del peso antes, se encuentra

<i>Dieta con harina de pescado</i>			
<i>Antes</i>	<i>Después</i>	<i>Diferencia</i>	<i>Rango</i>
56	142.0	86.0	9
31	101.0	70.0	8
29	90.0	61.0	6
27	88.2	61.2	7
25	81.3	56.3	5
23	77.0	54.0	4
21	74.0	53.0	3
21	54.4	33.4	2
18	51.2	33.2	1

con lo cual, $R^+ = 45$, $R^- = 0$ y $R = \min\{0, 45\} = 0$.

Con un nivel del 5% de significación al usar la tabla [A.6](#) del apéndice, se obtiene $R_0 = 8$ al 5% de significación y, como $R = 0 < R_0 = 8$, entonces se rechaza H_0 , concluyendo lo mismo que en el caso paramétrico.

2.6. Implementación en SAS

El código en el programa SAS a través del cual se obtuvieron los resultados de los ejemplos 2.1, 2.2 y 2.7 es el siguiente:

```
/* EJEMPLOS 2.1 Y 2.2 */
DATA EJEMPLO21;
INPUT ESPECIE $ PESO @@;
CARDS;
s 15.16 g 28.99 g 16.95 g 29.61 g 35.61 g 20.69 g 17.39 g 29.94 g 22.79
s 30.86 s 14.00 s 38.72 s 23.29 s 17.00 s 35.40 s 19.32 s 29.88
;
PROC PRINT DATA=EJEMPLO21;
RUN;

/* DIAGRAMA DE CAJAS */
PROC SORT DATA=EJEMPLO21;
BY ESPECIE;

PROC BOXPLOT DATA=EJEMPLO21;
PLOT PESO*ESPECIE;
RUN;

/* PRUEBAS DE IGUALDAD DE VARIANZAS */
PROC MEANS NOPRINT DATA=EJEMPLO21;
VAR PESO;
CLASS ESPECIE;
OUTPUT OUT=VARDOSESP N=_N1 MEAN=MEDIA STD=STAN VAR=VARI;
TITLE1 "PRUEBA DE VARIANZAS PARA EL PESO EN DOS ESPECIES";
RUN;
```

```

DATA VESTA;
  SET VARDOSESP END=_EOF_;
  WHERE _TYPE_ = 1;
  RETAIN N1-N2 MEDIA1-MEDIA2 DSTAN1-DSTAN2 VARI1-VARI2 VAL1-VAL2;
  SELECT (MOD(_N_,2));
    WHEN (1) DO;
      VAL1 = ESPECIE; N1 = _N1; MEDIA1 = MEDIA;
      VARI1 = VARI; DSTAN1 = DSTAN;
      RETURN;
    END;
  WHEN (0) DO;
      VAL2 = ESPECIE; N2 = _N1; MEDIA2 = MEDIA;
      VARI2 = VARI; DSTAN2 = DSTAN;
    END;
  END;
* --- CALCULA LA ESTADÍSTICA F Y LA PROBABILIDAD --- *;
  DF1 = N1 - 1; DF2 = N2 - 1;
  IF VARI2 > 0 THEN
    F = VARI1 / VARI2;
  ELSE F = .;
* PROBABILIDAD A DOS COLAS *;
  IF F NE . THEN DO;
    p = MIN(2*(1 - probf(F, DF1, DF2)),
      2*( probf(F, DF1, DF2)));
  END;
  ELSE p = .;
* --- CALCULA LOS INTERVALOS DE CONFIANZA --- *;
  INFERIOR = (VARI1 / VARI2) / finv(1-(1-0.95)/2, DF1, DF2);
  SUPERIOR = (VARI1 / VARI2) / finv( (1-0.95)/2, DF1, DF2);
  OUTPUT;

  FILE PRINT;
  PUT // @5 'ESTADÍSTICAS MUESTRALES'//;
  PUT @10 "ESPECIE";
  GRPLEN = MAX(LENGTH(VAL1),LENGTH(VAL2));
  IF GRPLEN < 10 THEN GRPLEN = 10;
  IF GRPLEN > 32 THEN DO;
    GRPLEN = 32;
    VAL1 = SUBSTR(VAL1,1,32);
    VAL2 = SUBSTR(VAL2,1,32);
  end;

* --- IMPRIME LOS RESULTADOS --- *;
  DASHES = REPEAT('-',GRPLEN+42+LENGTH('VARIANZA')-(10-1)-2);
  PUT @10 'GRUPO' @GRPLEN+15 'N' @GRPLEN+22 'MEDIA'
    @GRPLEN+30 'DES. STAD.' @GRPLEN+42 'VARIANZA';
  PUT @10 DASHES;
  PUT @10 VAL1 @GRPLEN+11 N1 5. @GRPLEN+18 MEDIA1 best8.
    @GRPLEN+32 DSTAN1 best6.

```

```

        @GRPLEN+42 VARI1 best8.;
PUT @10 VAL2 @GRPLEN+11 N2 5. @GRPLEN+18 MEDIA2 best8.
        @GRPLEN+32 DSTAN2 best6.
        @GRPLEN+42 VARI2 best8.;

PUT // @5 'PRUEBA DE HIPÓTESIS'//
        @10 'HIPÓTESIS NULA:' @30 "VARIANZA 1 / VARIANZA 2 = 1" /
        @10 'ALTERNATIVA:' @30 "VARIANZA 1 / VARIANZA 2 ^= 1" /;
PUT @22 '- GRADOS DE LIBERTAD -';
PUT @15 'F' @25 'Numer.' @35 'Denom.' @50 "Pr > F" /
        @10 46*'-';
PUT @10 F 7.2 @25 DF1 5. @35 DF2 5. @50 p pvalue6.4;
* --- IMPRIME LOS INTERVALOS DE CONFIANZA --- *;
        _CIPROB_ = 0.95 * 100;
PUT // @5 _CIPROB_
        +(-1) "% INTERVALO DE CONFIANZA DE LA RAZÓN DE LAS DOS VARIANZAS";
PUT / @20 'LIM_INFER' @35 'LIM_SUPER' /
        @20 11*'-' @35 11*'-';
PUT @23 INFERIOR best6. @38 SUPERIOR best6. ;
RUN;
TITLE1;

/* PRUEBAS DE IGUALDAD DE MEDIAS */

*** PRUEBA T PARA DOS MEDIAS ***;
PROC MEANS NOPRINT DATA=EJEMPLO21;
        VAR PESO;
        CLASS ESPECIE;
        OUTPUT OUT=HT2T N=_N MEAN=_MEAN STD=_STD STDERR=_STDERR VAR=_VAR;
        TITLE1 "PRUEBA T PARA DOS MUESTRAS (PESO DENTRO DE ESPECIE)";
RUN;

DATA TSTAT;
        SET HT2T END=_EOF_;
        WHERE _TYPE_ = 1;
        RETAIN _MEAN1-_MEAN2 _N1-_N2 _STD1-_STD2 _STDERR1-_STDERR2
        _VAR1-_VAR2 _VAL1-_VAL2;
        SELECT (MOD(_N_,2));
                WHEN (1) DO;
                        _VAL1 = ESPECIE; _MEAN1 = _MEAN; _N1 = _N;
                        _VAR1 = _VAR; _STD1 = _STD; _STDERR1 = _STDERR;
                        RETURN;
                END;
                WHEN (0) DO;
                        _VAL2 = ESPECIE; _MEAN2 = _MEAN; _N2 = _N;
                        _VAR2 = _VAR; _STD2 = _STD; _STDERR2 = _STDERR;
                        END;
        END;

```

```

* --- CALCULA LA PRUEBA T Y LAS PROBABILIDADES --- *;
  _DF_ = _N1 + _N2 - 2; _TOTN_ = _N1 + _N2;
  _PVAR_ = ((_N1-1)*_VAR1 + (_N2-1)*_VAR2)/_DF_;
  IF _PVAR_ > 0 THEN _T_ = (_MEAN1 - _MEAN2 - 0) /
    (SQRT(_PVAR_*(1/_N1+1/_N2)));
  ELSE _T_ = .;
  IF _T_ > 9999.999 THEN _T_ = 9999.999;
  _W1 = _VAR1/_N1; _W2 = _VAR2/_N2;
  IF (_W1 + _W2) > 0 THEN DO;
    _T_UNEQ = (_MEAN1 - _MEAN2 - 0) / SQRT(_W1 + _W2);
    _DF_UNEQ = (_W1 + _W2)**2/(_W1*_W1/(_N1-1) + _W2*_W2/(_N2-1));
  END;
  ELSE DO;
    _T_UNEQ = .;
    _DF_UNEQ = .;
  END;
  IF _T_UNEQ > 9999.999 THEN _T_UNEQ = 9999.999;
  IF _T_ NE . THEN
    _P_EQ = (1-PROBT(ABS(_T_),_DF_))*2; * PROBABILIDAD A DOS COLAS *;
  ELSE _P_EQ = .;
  IF _T_UNEQ NE . THEN
    _P_UNEQ = (1-PROBT(ABS(_T_UNEQ ),_DF_UNEQ))*2;
  ELSE _P_UNEQ = .;
* --- CALCULA LOS INTERVALOS DE CONFIANZA --- *;
  _INC_ = SQRT(_PVAR_*(1/_N1+1/_N2))*TINV( (1-0.95)/2,_DF_);
  _LOWER_ = _MEAN1 - _MEAN2 + _INC_;
  _UPPER_ = _MEAN1 - _MEAN2 - _INC_;
  OUTPUT;

  FILE PRINT;
  GRPLEN = MAX(LENGTH(_VAL1),LENGTH(_VAL2));
  IF GRPLEN < 10 THEN GRPLEN = 10;
  IF GRPLEN > 32 THEN DO;
    GRPLEN = 32;
    _VAL1 = SUBSTR(_VAL1,1,32);
    _VAL2 = SUBSTR(_VAL2,1,32);
  END;

* --- IMPRIME LOS RESULTADOS --- *;
  DASHES = REPEAT('-',GRPLEN+42+LENGTH('STD. ERROR')-(10-1)-2);
  PUT // @5 'ESTADÍSTICAS MUESTRALES'//
    @10 'GRUPO' @GRPLEN+15 'N' @GRPLEN+22 'MEDIA'
    @GRPLEN+30 'STD. DEV.' @GRPLEN+42 'STD. ERROR';
  PUT @10 DASHES;
  PUT @10 _VAL1 @GRPLEN+11 _N1 5. @GRPLEN+18 _MEAN1 BEST8.
    @GRPLEN+32 _STD1 BEST6. @GRPLEN+45 _STDERR1 BEST6.;
  PUT @10 _VAL2 @GRPLEN+11 _N2 5. @GRPLEN+18 _MEAN2 BEST8.
    @GRPLEN+32 _STD2 BEST6. @GRPLEN+45 _STDERR2 BEST6.;

```

```

PUT // @5 'PRUEBA DE HIPÓTESIS'//
@10 'HIPÓTESIS NULA:' @30 "MEDIA 1 - MEDIA 2 = 0" /
@10 'ALTERNATIVA:' @30 "MEDIA 1 - MEDIA 2 ^= 0" //
@10 'SI LAS VARIANZAS SON' @30 'ESTADÍSTICA T' @47 'GL' @56 'PR>T'/
@10 52*'- ' /
@10 'IGUAL' @30 _T_ 8.3 @43 _DF_ 6. @56 _P_EQ PVALUE6.4 /
@10 'NO IGUAL' @30 _T_UNEQ 8.3 @43 _DF_UNEQ 6.2
@56 _P_UNEQ PVALUE6.4;
* --- IMPRIME LOS INTERVALOS DE CONFIANZA --- *;
_CIPROB_ = 0.95 * 100;
PUT // @5 _CIPROB_ +(-1) "% INTERVALO DE CONFIANZA PARA LA
DIFERENCIA DE MEDIAS";
PUT / @20 'LÍMITE INFERIOR' @35 'LÍMITE SUPERIOR'/
@20 11*'- ' @35 11*'- ' ;
PUT @20 _LOWER_ 8.2 @35 _UPPER_ 8.2;
* --- ANÁLISIS DE POTENCIA --- *;
PUT // @5 "ANÁLISIS DE POTENCIA";
PUT / @32 'MUESTRA' @48 'OBSERVADO';
PUT @16 "ALPHA" @33 'TAMAÑO' @50 'POTENCIA'
/ @16 '-----' @33 '-----' @50 '-----';

* --- CALCULA LA POTENCIA --- *;
_DFE_ = _DF_; _DFM_ = _TOTN_ - _DFE_; _NC_ = _T_; _SSIZE_ = _TOTN_;
DO _ALPHA_ = .05;
IF _DF_ > 0 AND _T_ ^= . THEN DO;
_POWER_ = SDF("F",FINV(1-_ALPHA_,1,_DFE_,0),1,_DFE_,_NC*_NC_);
IF _POWER_ > .999 THEN _POWER_ = 0.999;
END;
ELSE _POWER_ = .;
* --- IMPRIME EL ANÁLISIS DE POTENCIA --- *;
PUT @16 _ALPHA_ 5.3 @31 _SSIZE_ 6. @50 _POWER_ 5.3;
END;

RUN;
TITLE1;
PROC DELETE DATA=HT2T;
RUN;

/* PRUEBAS DE IGUALDAD DE MEDIAS Y DE VARIANZAS */
PROC TTEST DATA=EJEMPLO21;
CLASS ESPECIE;
VAR PESO;
RUN;

/* GRÁFICO DE NORMALIDAD Y PRUEBAS DE NORMALIDAD */
PROC UNIVARIATE DATA=EJEMPLO21 NORMAL PLOT;
VAR PESO;
QQPLOT PESO;
RUN;

```

```

/* EJEMPLO 2.3 */
DATA EJEMPLO23;
DO NITROGENO=1 TO 2;
    INPUT PESOS @@; OUTPUT;
END;
CARDS;
0.32 0.26 0.53 0.43 0.28 0.47 0.37 0.49 0.47 0.52 0.43 0.75 0.36
0.79 0.42 0.86 0.38 0.62 0.43 0.46
;
PROC PRINT DATA=EJEMPLO23;
RUN;

/* DIAGRAMA DE CAJAS */
PROC SORT DATA=EJEMPLO23;
BY NITROGENO;

PROC BOXPLOT DATA=EJEMPLO23;
PLOT PESOS*NITROGENO;
RUN;

/* PRUEBAS DE IGUALDAD DE MEDIAS Y DE VARIANZAS */
PROC TTEST DATA=EJEMPLO23;
CLASS NITROGENO;
VAR PESOS;
RUN;

/* GRÁFICO DE NORMALIDAD Y PRUEBAS DE NORMALIDAD */
PROC UNIVARIATE DATA=EJEMPLO23 NORMAL PLOT;
VAR PESOS;
QQPLOT PESOS;
RUN;

/* EJEMPLO 2.7 */
/* PRUEBA NO PARAMÉTRICA DE WILCOXON */
PROC NPAR1WAY DATA=EJEMPLO21 WILCOXON;
CLASS ESPECIE;
VAR PESO;
RUN;

```

2.7. Implementación en R

El código en el programa R a través del cual se obtuvieron los resultados de los ejemplos 2.1, 2.2, 2.3, 2.4, 2.6, 2.7, 2.8 y 2.9 es el siguiente:

```

#####
# Ejemplo 2.1 #
#####
# Lectura de datos #

```



```

peso <- c(15.16,28.99,16.95,29.61,34.61,20.69,17.39,29.94,22.79,30.86,14.00,
          38.72,23.29,17.00,35.40,19.32,29.88)
# g= tilapias Gregori; s=tilapias SantaFe
especie <- c('s',rep('g',8),rep('s',8))
# Prueba gráfica de homogeneidad e igualdad de medias #
boxplot(peso ~ especie)
# Gráfico de normalidad #
qqnorm(peso)
qqline(peso)

# Prueba paramétrica de normalidad #
shapiro.test(peso)

# Prueba de igualdad de medias #
t.test(peso~especie,var.equal=T,alternative="greater")

#####
# Ejemplo 2.2 #
#####
# ¿Se puede suponer que las varianzas son +/- iguales? #
var.test(peso~ especie=='g')

#####
# Ejemplo 2.3 #
#####
# Lectura de datos #
peso.tallos <- c(0.32,0.53,0.28,0.37,0.47,0.43,0.36,0.42,0.38,0.43,
                0.26,0.43,0.47,0.49,0.52,0.75,0.79,0.86,0.62,0.46)
nitrogeno <- c(rep('noN',10),rep('siN',10))#noN= Sin Nitrógeno; siN=ConNitrógeno
# Prueba gráfica de homogeneidad e igualdad de medias #
boxplot(peso.tallos ~ nitrogeno)
# ¿Podemos suponer que las varianzas son +/- iguales? #
var.test(peso.tallos ~ nitrogeno)

# Prueba de igualdad de medias #
t.test(peso.tallos ~ nitrogeno,var.equal=F)
# Gráfico de normalidad #
qqnorm(peso.tallos)
qqline(peso.tallos)
# Prueba paramétrica de normalidad #
shapiro.test(peso.tallos)

#####
# Ejemplo 2.4 #
#####
# Prueba no paramétrica de Wilcoxon #
wilcox.test(peso~especie=='g', paired = F, alternative = "greater")

```

```
#####
# Ejemplo 2.6 #
#####
# Estimación robusta #
t.test(peso~especie,var.equal=T,alternative="greater")

#####
# Ejemplo 2.7 #
#####
# Lectura de datos #
agente.osmo <- c(rep('SC',6),rep('SS',6)) # SC = Sacarosa Cristalina,
#SS = Sal Sólida
brix <- c(17.0,17.5,17.2,21.0,20.5,20.7,30.0,29.0,29.5,31.0,31.0,30.0)
PH <- c(5.05,5.07,5.02,5.15,5.17,5.12,4.21,4.24,4.18,4.13,4.16,4.18)
osmo <- as.data.frame(agente.osmo)
osmo$brix <- brix
osmo$PH <- PH

# Prueba T^2 de Hotelling #
library(Hotelling)
library(corpcor)
split.data <- split(osmo[, -1], osmo$agente.osmo)
x <- split.data[[1]]
y <- split.data[[2]]

S <- 1/10*(5*cov(x) + 5*cov(y))
S <- (5*cov(x) + 5*cov(y))
T <- 36/12*cbind(mean(x$brix)-mean(y$brix),mean(x$PH)-mean(y$PH))
%%solve(S)*%rbind(mean(x$brix)-mean(y$brix),mean(x$PH)-mean(y$PH))
T
ST <- hotelling.stat(x, y)
ST
fit <- hotelling.test(brix+PH ~ agente.osmo, data=osmo)
fit

#####
# Ejemplo 2.8 #
#####
# Prueba simultánea de media y varianzas #
antes <- c(56,31,29,27,25,23,21,21,18)
despues <- c(142,101,90,88.2,81.3,77,74,54.4,51.2)

# Prueba de igualdad de medias en comparación pareada #
anova(lm(despues ~ antes))
SCE <- anova(lm(despues ~ antes))$'Sum Sq'[2] #suma de cuadrados del error
dif <- sum((antes-despues)^2) #suma de las diferencias al cuadrado
SCE;dif
FC <- ((dif-SCE)/2)/(SCE/7)
FC
```

```
#####
# Ejemplo 2.9 #
#####
# Prueba no paramétrica de Wilcoxon para datos pareados #
wilcox.test(antes, despues, paired = T)
```

2.8. Ejercicios

1. Cierta metal se produce, por lo común, mediante un proceso estándar. Se desarrolla un nuevo proceso en el que se añade una aleación a la producción de metal. Los fabricantes se encuentran interesados en estimar la verdadera diferencia entre las tensiones de la ruptura de los metales producidos por los dos procesos. Para cada metal se seleccionan 12 especímenes y cada uno de estos se somete a tensión hasta que se rompe. La siguiente tabla muestra las tensiones de ruptura de los especímenes en kilogramos por centímetro cuadrado:

Proceso estándar	Proceso nuevo
428	462
419	448
458	435
439	465
441	429
456	472
463	453
429	459
438	427
445	468
441	452
463	447

Si se supone que el muestreo se lleva a cabo sobre dos distribuciones normales e independientes, pruebe la hipótesis de igualdad de medias y obtenga un intervalo de confianza 95 % para la diferencia de medias poblacionales de los procesos. Con base en los resultados, ¿se estaría inclinado a concluir que existe una diferencia real entre media del proceso estándar y el nuevo?

2. Realice el ejercicio 1 sin suponer normalidad.
3. Se realizó un estudio para determinar el grado en el cual el alcohol entorpece la habilidad de pensamiento para realizar determinada tarea. Se seleccionaron aleatoriamente diez personas de distintas características y se les pidió que participaran en el experimento. Después de

proporcionarles la información pertinente, cada persona llevó a cabo la tarea sin nada de alcohol en su organismo. La tarea volvió a realizarse después de que cada persona había consumido una cantidad suficiente de alcohol para tener un contenido en su organismo del 0.1 %. Suponga que los tiempos antes y después (en minutos) de los diez participantes son los siguientes:

Participante	Antes	Después
1	28	39
2	22	45
3	55	67
4	45	61
5	32	46
6	35	58
7	40	51
8	25	34
9	37	48
10	20	30

¿Puede concluirse a un nivel de significación del 5 % que el tiempo promedio antes es menor que el tiempo promedio después por más de 10 minutos?

4. Dos universidades financiadas por el Gobierno tienen métodos distintos para inscribir sus alumnos a principio de cada semestre. Las dos desean comparar el tiempo promedio que les toma a los estudiantes completar el trámite de inscripción. En cada universidad se anotaron los tiempos de inscripción para 100 alumnos seleccionados aleatoriamente. Las medias y las desviaciones estándares muestrales son las siguientes:

$$\bar{x}_1 = 50.2, \bar{x}_2 = 52.9, s_1 = 4.8 \text{ y } s_2 = 5.4$$

- a. Si se supone que el muestreo se realizó sobre dos poblaciones distribuidas normales e independientes, obtenga la prueba estadística. ¿Se estaría inclinado a concluir que existe una diferencia real entre los tiempos medios para cada universidad?
- b. Basados en el supuesto hecho en a., construya los intervalos de confianza estimados del 95 % para la diferencia entre las medias del tiempo de inscripción para las dos universidades. ¿Se estaría inclinado a concluir que existe una diferencia real entre los tiempos medios para cada universidad?

5. Se investiga el diámetro de las varillas de acero fabricadas en dos diferentes máquinas de extrusión. Para ello, se toman dos muestras aleatorias de tamaños $n_1 = 15$ y $n_2 = 18$; las medias y las varianzas muestrales son $\bar{x}_1 = 8.73$, $s_1^2 = 0.35$, $\bar{x}_2 = 8.68$, $s_2^2 = 0.40$, respectivamente. Pruebe la hipótesis de que el diámetro promedio de las varillas es igual y construya un intervalo de confianza bilateral del 95 % para la diferencia en el diámetro promedio de la varilla.
6. Los niños con neurosis y con ligero retraso que asisten a una clínica de evaluación de desarrollo en un hospital se dividieron en dos grupos con base en la presencia o ausencia de un probable factor etiológico que produce el retraso mental. Se midió la concentración de plomo en la sangre de cada niño, obteniéndose los siguientes resultados:

Factor ausente	25.5	23.2	27.6	24.3	26.1	25.0
Factor presente	21.2	19.8	20.3	21.0	19.6	

¿Indican los datos alguna diferencia en la magnitud de variabilidad de la concentración de plomo en la sangre para los dos tipos de niños? Utilice un nivel de significación del 10 % para dar soporte estadístico a su conclusión.

7. Los siguientes datos fueron tomados de Winer (1991), de un pequeño experimento.

Tratamiento 1		Tratamiento 2	
Y_1	Y_2	Y_1	Y_2
3	10	7	14
6	18	9	22
5	22	5	19
8	20	10	24
4	16	10	26
7	19	9	18

¿Los dos tratamientos presentan los mismos promedios? Pruebe la hipótesis de interés asumiendo normalidad en los datos.

8. Las siguientes observaciones son los resultados de una prueba realizada a 19 pacientes con cáncer, 13 de los cuales murieron dos años después y los restantes sobrevivieron. Se desea probar si hay una relación entre las pruebas para pacientes que sobrevivieron y los que fallecieron al medir el nivel de proteínas en la sangre, realice la prueba pertinente para responder esta inquietud.

Tipo de paciente	Nivel de proteínas en la sangre												
Fallecieron	16	30	0	2	14	35	6	9	1	34	1	4	7
Sobrevivieron	23	0.8	0.1	0.1	0.2	0.1							

9. Un profesor quería probar si sus estudiantes tendían a tener mejores calificaciones en sus pruebas dependiendo de la jornada de aplicación de la misma (mañana o tarde). De un grupo de 19 estudiantes con talentos similares, él seleccionó aleatoriamente algunos para realizarles la prueba en la mañana y otros para realizarla en la tarde. Las calificaciones por grupos fueron:

Mañana	89.8	87.3	90.2	87.6	98.1	87.3	91.2	91.8	88.9				
Tarde	86.4	90.3	86.4	99.2	93.1	94.0	89.2	88.7	90.1	83.9			

- Realice la prueba de Mann-Whitney para juzgar la existencia de diferencias en las calificaciones según la jornada.
 - Cambie la calificación 83.9 en el segundo grupo por 11 y realice de nuevo la prueba correspondiente. ¿Este cambio altera el estadístico de prueba o la conclusión?
 - Compare los resultados obtenidos en los ítems a. y b. con los obtenidos al realizar una prueba haciendo uso del estadístico t tanto para los datos originales como para los datos con el cambio considerado. ¿Este cambio altera las conclusiones obtenidas a través del uso de este estadístico?
 - Realice un gráfico para comparar los datos originales con los datos que tienen el cambio y concluya.
10. En un estudio sobre el lagarto *Sceloporus occidentalis* se estudió cual era el impacto ecológico de la infección por el parásito de malaria *Plasmodium*, en lagartos que no estaban en cautividad. Para ello, se investigó la respuesta de 14 lagartos infectados y 14 no infectados a una prueba de resistencia. Los resultados vienen dados por la distancia (en metros) que cada animal recorría en dos minutos.


Infectados	16.4	29.4	37.1	23.0	24.1	24.5	37.1
	16.4	29.1	36.7	28.7	30.2	21.8	20.3
No infectados	22.2	34.8	42.1	32.9	26.4	30.6	45.5
	32.9	37.5	18.4	27.5	45.5	34.0	24.5

- Si se supone que el muestreo se lleva a cabo sobre dos distribuciones normales, pruebe la hipótesis de igualdad de medias al nivel significación del 5%.

- b. Obtenga e interprete un intervalo de confianza 95 % para la diferencia de medias poblacionales de los procesos del ítem a).
 - c. Si se supone que el muestreo se lleva a cabo sobre dos distribuciones no normales, pruebe la hipótesis de igualdad al nivel significación del 5 %.
11. En un estudio sobre el efecto de la cafeína en el metabolismo muscular, se tomaron 18 hombres voluntarios, quienes se sometieron a pruebas de ejercicio en la armada. Nueve de ellos fueron seleccionados aleatoriamente para tomar una cápsula que contenía cafeína pura una hora antes de la prueba; los otros recibieron una cápsula placebo. Durante cada prueba se midió la razón de cambio respiratoria (RCR), esta es la razón entre CO_2 producido y O_2 consumido, la cual es un indicador de si la energía está siendo obtenida de los carbohidratos o grasas. La pregunta de interés para el experimentador fue determinar si la cafeína afecta la RCR. Si la cafeína no tiene efecto sobre esta razón, los dos conjuntos de datos se podría considerar que provienen de la misma población. Los resultados de los ensayos fueron los siguientes:

Placebo	Cafeína
105	96
119	99
100	94
97	89
96	96
101	93
94	88
95	105
98	88

Juzgue la hipótesis de interés para el experimentador haciendo uso de pruebas paramétricas y no paramétricas pertinentes, y, luego, compare las conclusiones obtenidas por los dos métodos.



Capítulo *tres* Modelos de análisis de varianza

3.1. Introducción

Dada la importancia de los modelos lineales como herramienta para el análisis estadístico de los ensayos experimentales, en este capítulo se lleva a cabo una breve revisión, se presentan inicialmente algunas ideas básicas sobre modelos lineales superparametrizados, modelos de medias de celdas y modelos con restricciones Σ . Así mismo, se presentan los diferentes tipos de sumas de cuadrados y el concepto de funciones estimables, resultados relevantes en el desarrollo de la metodología de este texto.

3.2. Conceptos básicos de modelos lineales

En experimentación se plantea, en general, el siguiente modelo:

$$Y = X\theta + e, \quad (3.1)$$

donde $Y_{n \times 1}$ es un vector de variables aleatorias, $X_{n \times p}$ es una matriz de efectos conocida (matriz de diseño) de rango $k \leq \min\{n, p\}$, $\theta_{p \times 1}$ es un vector de parámetros desconocidos y $e_{n \times 1}$ es un vector de variables aleatorias no observables, se supone, además que $e_{n \times 1} \sim N(\mathbf{0}, \sigma^2 I_{n \times n})$, con $\mathbf{0}$ un vector de ceros e $I_{n \times n}$ una matriz identidad de tamaño n .

En el caso concreto de modelos de clasificación, el modelo (3.1) se puede observar desde diferentes escenarios: el *modelo superparametrizado* (modelo S) presentado por Searle (1971). El uso de este modelo facilita la interpretación de las sumas de cuadrados obtenidas a partir de la notación $R(\cdot/\cdot)$ introducida por (Searle 1987); el *modelo de medias de celda* (modelo M) propuesto por Hocking y Speed (1975) ayuda a simplificar la interpretación de algunas hipótesis y el *modelo Σ restringido*, el cual es esencial para la interpretación de ciertos tipos de sumas de cuadrados de rango completo. El estudio de estos modelos se describe en forma general en la siguiente sección, sin embargo, brevemente se estudiarán a continuación.

3.2.1. Modelo superparametrizado (Modelo S)

El modelo superparametrizado presentado en Searle (1971) muestra en forma explícita todo el conjunto de parámetros para los diferentes factores involucrados en el modelo. El modelo se puede expresar como en (3.1) y se conoce en la literatura como modelo S.

3.2.1.1. Estimación de parámetros

Para la estimación del conjunto de parámetros en el modelo (3.1), se minimiza la suma de cuadrados del error, la cual conlleva al sistema de ecuaciones normales ($\mathbf{X}^t \mathbf{X} \boldsymbol{\theta}^0 = \mathbf{X}^t \mathbf{Y}$). La estimación del vector de variables aleatorias $\boldsymbol{\epsilon}$ depende de la caracterización de las ecuaciones $\mathbf{X}^t \mathbf{X} \boldsymbol{\theta}^0 = \mathbf{X}^t \mathbf{Y}$, la cual es consistente con $\boldsymbol{\theta}^0$ una aproximación de mínimos cuadrados para $\mathbf{Y} = \mathbf{X} \boldsymbol{\theta}$ inconsistente. Esto lleva a que cualquier solución $\boldsymbol{\theta}^0$ del sistema de ecuaciones normales genere un vector $\hat{\mathbf{Y}} = \mathbf{X} \boldsymbol{\theta}^0$ invariante para toda solución de las ecuaciones normales el cual es una aproximación de mínimos cuadrados para el vector $\mathbf{Y}$ de observaciones (ver más detalles en Searle 1987).

Si la matriz $\mathbf{X}$ es de rango columna completo, entonces $\mathbf{X}^t \mathbf{X}$ es definida positiva y, por tanto, es no singular. En este caso, el sistema $\mathbf{X}^t \mathbf{X} \boldsymbol{\theta}^0 = \mathbf{X}^t \mathbf{Y}$ tiene solución única dada por $\hat{\boldsymbol{\theta}} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y}$ y la solución aproximada de mínimos cuadrados para $\hat{\mathbf{Y}} = \mathbf{X} \hat{\boldsymbol{\theta}}$ coincide con el estimador de mínimos cuadrados para $\boldsymbol{\theta}$, esto garantiza que cada componente del vector $\boldsymbol{\theta}$ es estimable en forma única.

Por otro lado, si $\mathbf{X}$ no es de rango columna completo, entonces $\mathbf{X}^t \mathbf{X}$ no es definida positiva y, por lo tanto, es singular. Con estas condiciones, el sistema de ecuaciones normales es indeterminado y tiene como solución $\boldsymbol{\theta}^0 = (\mathbf{X}^t \mathbf{X})^- \mathbf{X}^t \mathbf{Y}$, siendo una solución aproximada de mínimos cuadrados para $\mathbf{Y} = \mathbf{X} \boldsymbol{\theta}$ inconsistente y $(\mathbf{X}^t \mathbf{X})^-$ una inversa generalizada de $\mathbf{X}^t \mathbf{X}$. En este caso, $\boldsymbol{\theta}^0$ no es más el estimador de mínimos cuadrados para $\boldsymbol{\theta}$. Por lo tanto, los componentes del vector $\boldsymbol{\theta}$ no son individualmente estimables.

3.2.1.2. Análisis de varianza

En el modelo de rango incompleto, como $\hat{\mathbf{Y}} = \mathbf{X} \boldsymbol{\theta}^0$ es invariante para todo $\boldsymbol{\theta}^0$ solución de las ecuaciones normales, entonces $\hat{\mathbf{Y}}$ puede ser expresado de la forma $\hat{\mathbf{Y}} = \mathbf{P} \mathbf{Y}$, siendo $\mathbf{P} = \mathbf{X} (\mathbf{X}^t \mathbf{X})^- \mathbf{X}^t = \mathbf{X} \mathbf{X}^+ = \mathbf{X} \mathbf{X}^l$ el proyector ortogonal de $\mathbf{Y}$ en el espacio generado por las columnas de $\mathbf{X}$, ($\mathbf{X} \in \mathcal{C}(\mathbf{X})$), con $\mathbf{X}^l$ y $\mathbf{X}^+$ las inversas generalizadas de mínimos cuadrados y Moore-Penrose, respectivamente (Iemma 1993).

En la figura 3.1, se muestra una descomposición de $\mathbf{Y} \in \mathfrak{R}^n$ en la suma de dos subespacios ortogonales; $\hat{\mathbf{Y}} = \mathbf{P} \mathbf{Y}$, que pertenece a $\mathcal{C}(\mathbf{X})$, y $\hat{\boldsymbol{\epsilon}} = \mathbf{Y} - \hat{\mathbf{Y}} = (\mathbf{I} - \mathbf{P}) \mathbf{Y}$, perteneciente al complemento ortogonal del espacio columna de $\mathbf{X}$, ($\hat{\boldsymbol{\epsilon}} \in \mathcal{C}^\perp(\mathbf{X})$).

Con base en la figura 3.1 se satisface la siguiente desigualdad

$$\|\mathbf{Y}\|^2 = \|\hat{\mathbf{Y}}\|^2 + \|\hat{\boldsymbol{\epsilon}}\|^2, \quad (3.2)$$

donde $\|Y\|^2 = Y^t Y = \sum_i y_i^2$ hace referencia a la suma de cuadrados total no corregida, $\|\hat{Y}\|^2 = \|PY\|^2 = Y^t PY$, la suma de cuadrados de los parámetros (suma de cuadrados del modelo) y $\|\hat{e}\|^2 = \|(I - P)Y\|^2 = Y^t (I - P)Y$, la suma de cuadrados de los residuales.




Figura 3.1: Descomposición de la proyección ortogonal del vector Y , en el espacio columna de X ($\mathcal{C}(X)$).

Las sumas de cuadrados asociados con el modelo (3.1) pueden ser descritas a través de la notación R (Speed, Hocking y Hackney 1978), la cual es útil en la caracterización de la suma de cuadrados en los modelos S.

La notación $R(\cdot/\cdot)$, para el modelo dado en (3.1), es definida por

$$R(\theta) = (\theta^0)^t X^t Y, \quad (3.3)$$

donde θ^0 es una solución al sistema de ecuaciones normales $X^t X \theta = X^t Y$. En el ejemplo 3.1 se presentan los resultados para este modelo.

Ejemplo 3.1. *Considérese el conjunto de datos de la tabla 3.1. En este caso, cada observación se puede caracterizar mediante el modelo*

$$y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + e_{ijk}, \quad i = 1, 2, \quad j = 1, 2, 3, \quad k = 1, \dots, n_{ij} \quad (n_{ij} \geq 0).$$

En términos del modelo (3.1) se estructura de la siguiente forma

$$\begin{bmatrix} Y_{111} \\ Y_{112} \\ Y_{121} \\ Y_{131} \\ Y_{132} \\ Y_{211} \\ Y_{212} \\ Y_{221} \\ Y_{222} \\ Y_{223} \end{bmatrix} = \begin{bmatrix} 7 \\ 9 \\ 8 \\ 2 \\ 4 \\ 5 \\ 7 \\ 14 \\ 15 \\ 19 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \gamma_{11} \\ \gamma_{12} \\ \gamma_{13} \\ \gamma_{21} \\ \gamma_{22} \end{bmatrix} + \begin{bmatrix} e_{111} \\ e_{112} \\ e_{121} \\ e_{131} \\ e_{132} \\ e_{211} \\ e_{212} \\ e_{221} \\ e_{222} \\ e_{223} \end{bmatrix}.$$

Tabla 3.1: Arreglo factorial 2×3 para un conjunto de datos ficticios

	j=1	j=2	j=3
i=1	$Y_{111} = 7$	$Y_{121} = 8$	$Y_{131} = 2$
	$Y_{112} = 9$	—	$Y_{132} = 4$
	μ_{11}	μ_{12}	μ_{13}
i=2	$Y_{211} = 5$	$Y_{221} = 14$	—
	$Y_{212} = 7$	$Y_{222} = 15$	—
	—	$Y_{223} = 19$	—
	μ_{21}	μ_{22}	

Si se supone que los errores se distribuyen con media 0 y varianza constante σ^2 , la solución de mínimos cuadrados θ^0 es

$$[\hat{\mu}, \hat{\alpha}_1, \hat{\alpha}_2, \hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3, \hat{\gamma}_{11}, \hat{\gamma}_{12}, \hat{\gamma}_{13}, \hat{\gamma}_{21}, \hat{\gamma}_{22}]^t = [11, -8, 0, -5, 5, 0, 10, 0, 0, 0, 0]^t.$$

Para este conjunto de datos, la descomposición de la suma de cuadrados y el ANOVA se muestra en la tabla 3.2. Con base en los resultados obtenidos en dicha tabla, si se desea juzgar $H_0 : \mathbf{X}\theta = \mathbf{0}$ en el modelo (3.1), se encuentra que esta se rechaza (valor $p = 0.0054$), con lo cual al menos uno de los dos factores tiene algún efecto significativo con la variable respuesta.

Tabla 3.2: Tabla de análisis de varianza para los datos del ejemplo 3.1

C de V	gl	Sumas de cuadrados	Cuadrados medios	Valor F	Pr>F
Modelo	4	240	60	15	0.0054
Error	5	20	4		
Total _{CM}	9	260			

3.2.2. Modelo de medias de celdas

Los modelos superparametrizados han sido de gran utilidad, ya que ellos muestran explícitamente cada uno de los parámetros del modelo. Sin embargo, Speed et al. (1978), Hocking (1985), Searle (1987), entre otros, afirman que estos modelos presentan algunos inconvenientes como por ejemplo poseer más parámetros que medias de celda para estimarlos. Este problema se acentúa aún más con la presencia de celdas vacías. Por lo anterior, proponen los modelos de medias de celdas, en comparación con el modelo S presentan la ventaja de describir hipótesis con gran simplicidad.

En Speed et al. (1978), se define el modelo de medias de celda o modelo M como

$$\mathbf{Y} = \mathbf{W}\boldsymbol{\mu} + \mathbf{e}, \quad (3.4)$$

donde $\mathbf{W}_{n \times k}$ es una matriz conocida, $\boldsymbol{\mu}_{k \times 1}$ es un vector de medias poblacionales de las cuales han sido extraídas las muestras aleatorias que componen las celdas, $\mathbf{Y}_{n \times 1}$ y $\mathbf{e}_{n \times 1}$ son definidos como en el modelo lineal superparametrizado (3.1).

3.2.2.1. Ecuaciones normales

El sistema de ecuaciones normales $\mathbf{W}^t \mathbf{W} \boldsymbol{\mu} = \mathbf{W}^t \mathbf{Y}$, es en general, mucho más simple que las ecuaciones normales asociadas al modelo (3.1). Esto porque en la ecuación (3.4) $\mathbf{W}$ tiene rango columna completo. En este contexto, el sistema tiene solución única, esto es

$$\hat{\boldsymbol{\mu}} = (\mathbf{W}^t \mathbf{W})^{-1} \mathbf{W}^t \mathbf{Y}, \quad (3.5)$$

la cual coincide con la estimación de mínimos cuadrados para $\boldsymbol{\mu}$.

De la solución (3.5) se satisface que el mejor estimador lineal insesgado (MELI) de $\mu_{ij \dots k}$ es $\bar{Y}_{ij \dots k}$, es decir, MELI $(\lambda^t \boldsymbol{\mu}) = \lambda^t \hat{\boldsymbol{\mu}}$, solución de las ecuaciones normales $\mathbf{W}^t \mathbf{W} \boldsymbol{\mu} = \mathbf{W}^t \mathbf{Y}$ y la aproximación por mínimos cuadrados para el vector de observaciones $\mathbf{Y}$, está dado por $\hat{\mathbf{Y}} = \mathbf{W} \hat{\boldsymbol{\mu}}$.

Retomando los datos de la tabla 3.1, el modelo se puede escribir como $y_{ijk} = \mu_{ij} + e_{ijk}$, con $\mu_{ij} = \mu + \alpha_i + \beta_j + \gamma_{ij}$, se observa que el vector de parámetros se reduce a las medias de las celdas en términos del modelo (3.4). Para ilustrar este modelo, se vuelve a los datos del arreglo presentado en la tabla 3.1.

En forma matricial cada una de las observaciones se pueden resumir en el siguiente modelo:

$$\begin{bmatrix} Y_{111} \\ Y_{112} \\ Y_{121} \\ Y_{131} \\ Y_{132} \\ Y_{211} \\ Y_{212} \\ Y_{221} \\ Y_{222} \\ Y_{223} \end{bmatrix} = \begin{bmatrix} 7 \\ 9 \\ 8 \\ 2 \\ 4 \\ 5 \\ 7 \\ 14 \\ 15 \\ 19 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mu_{11} \\ \mu_{12} \\ \mu_{13} \\ \mu_{21} \\ \mu_{22} \end{bmatrix} + \begin{bmatrix} e_{111} \\ e_{112} \\ e_{121} \\ e_{131} \\ e_{132} \\ e_{211} \\ e_{212} \\ e_{221} \\ e_{222} \\ e_{223} \end{bmatrix}.$$

Bajo el supuesto de que los errores tiene media 0 y varianza constante, se llega a la siguiente solución de mínimos cuadrados

$$[\hat{\mu}_{11}, \hat{\mu}_{12}, \hat{\mu}_{13}, \hat{\mu}_{21}, \hat{\mu}_{22}]^t = [8, 8, 3, 6, 16]^t.$$

Al realizar el análisis de varianza para el modelo (3.4), se encuentran los mismos resultados que los obtenidos en el caso del modelo superparametrizado, en este caso, para probar la hipótesis de igualdad de medias.

3.3. Estimabilidad

Las funciones estimables para la obtención de proyectores ortogonales asociados con hipótesis dadas, cualquiera sea el nivel de desbalanceamiento de los datos, se presentan en la siguiente definición.

Definición 3.1. Una función lineal de los parámetros $\lambda^t \theta$ es estimable en el modelo (3.1) si y solo si existe una combinación lineal de las observaciones $a^t Y$ tal que $E(a^t Y) = \lambda^t \theta$.

De la definición anterior, se sigue que $\lambda^t \theta$ es estimable si $a^t X \theta = \lambda^t \theta$ y se puede tomar el sistema de ecuaciones lineales $X^t a = \lambda$, donde $a = (X^+)^t \lambda$ es una solución, puesto que λ^t pertenece al espacio columna de X , ($\lambda^t \in \mathcal{C}(X)$).

Si $\lambda^t \theta$ es estimable, con λ^t de rango fila completo, entonces se puede plantear la hipótesis lineal $H_0 : \lambda^t \theta = \mathbf{0}$, la cual tiene como suma de cuadrados asociada

$$SCH_0 = (\lambda^t \theta^0)^t [\lambda^t (X^t X)^- \lambda]^{-1} (\lambda^t \theta^0), \quad (3.6)$$

que en términos de proyectores ortogonales, se puede expresar como

$$SCH_0 = Y^t a (a^t a)^{-1} a^t Y = Y^t P_{H_0} Y, \quad (3.7)$$

la cual constituye una forma simple y práctica para el cálculo de sumas de cuadrados asociados con una hipótesis lineal; resultados que pueden verse en Iemma, López y Rincón (1999).

Sea el modelo lineal (3.1), en el cual se satisface que $E(Y) = X \theta$, el interés inicial es estimar parámetros de θ o alguna combinación lineal de estos, notados por $\lambda^t \theta$, a partir de una combinación lineal de los componentes del vector Y que tengan como valor esperado $\lambda^t \theta$, la cual es estimable si y solo si existe una combinación lineal de los componentes del vector Y cuyo valor esperado es $\lambda^t \theta$ (Rao y Mitra 1971).

De esta manera, las filas de X forman un conjunto generador del cual un $\lambda^t \theta$ puede ser estimado. Como X puede ser construida de las filas de $X^t X$, esto es $X = X (X^t X)^- (X^t X)$, las filas de $X^t X$ forman también un conjunto generador a partir del cual la base de las funciones estimables λ^t

puede ser construida. De la misma manera, las filas de la forma escalonada reducida $(X^t X)^-(X^t X) = H$ constituyen un conjunto generador para λ^t .

Una vez determinado el conjunto generador de λ^t , en el cual λ^t tiene rango fila completo, $\lambda^t \theta$ puede ser estimado por $\lambda^t \theta^0$, con θ^0 solución de las ecuaciones normales $X^t X \theta = X^t Y$.

3.3.1. Estimadores lineales insesgados (ELIS)

Al considerar el modelo (3.1), se está interesado en un estimador lineal insesgado de θ o de una combinación lineal de θ , por ejemplo $\lambda^t \theta$. Por Gauss-Markov, se satisface que $E(a^t Y) = \lambda^t \theta$ y si $\lambda^t \theta$ puede ser estimado insesgadamente, entonces es llamado un estimador lineal insesgado (ELI). Se evidencia a partir de la definición 3.1 que $E(a^t Y) = a^t X \theta$, luego $\lambda^t \theta$ es estimable.

A continuación se presentan algunos métodos, a través de un ejemplo, para verificar si un conjunto de funciones paramétricas es estimable, lo que puede verificarse con más detalle en Henderson (1984).

Ejemplo 3.2. Considere la siguiente matriz diseño:

$$X = \begin{bmatrix} 1 & 1 & 2 \\ 1 & 2 & 4 \\ 1 & 1 & 2 \\ 1 & 3 & 6 \end{bmatrix}, \text{ con } \theta^t = [\theta_0, \theta_1, \theta_2].$$

- i) ¿Es θ_0 estimable?, es decir, ¿ $\lambda_1^t \theta = (1 \ 0 \ 0) \theta$ es estimable?
- ii) ¿ $\theta_1 + 2\theta_2$ es estimable?, es decir, ¿ $\lambda_2^t \theta = (0 \ 1 \ 2) \theta$ es estimable?
- iii) ¿ θ_1 es estimable?, es decir, ¿ $(0 \ 1 \ 0) \theta$ es estimable?

Método 1. Para que sea estimable se debe satisfacer que $a^t X = \lambda^t$. Por consiguiente, realizando este procedimiento matricialmente se llega:

En i)

$$(2 \ -1 \ 0 \ 0)X = (2 \ -1 \ 0 \ 0) \begin{bmatrix} 1 & 1 & 2 \\ 1 & 2 & 4 \\ 1 & 1 & 2 \\ 1 & 3 & 6 \end{bmatrix} = (1 \ 0 \ 0) = \lambda_1^t$$

En ii)

$$(-1 \ 1 \ 0 \ 0)X = (-1 \ 1 \ 0 \ 0) \begin{bmatrix} 1 & 1 & 2 \\ 1 & 2 & 4 \\ 1 & 1 & 2 \\ 1 & 3 & 6 \end{bmatrix} = (0 \ 1 \ 2) = \lambda_2^t.$$

Luego θ_0 y $\theta_1 + 2\theta_2$ son estimables.

En iii), como $\lambda_3^t \theta = (0 \ 1 \ 0) \theta$, se evidencia que no es una función estimable, pues no existe a^t tal que satisfaga $a^t X = \lambda_3^t$.

Método 2. Este método consiste en particionar X en $X = [X_1 : X_1 D]$, donde X_1 tiene r funciones columnas linealmente independientes y D es de dimensión $(p-r)$. $\lambda^t \theta$ es estimable si y solo si $\lambda^t = [K_1^t : K_1^t D]$, donde K_1^t tiene r elementos y $K_1^t D$ tiene $(p-r)$ elementos.

Retomando el ejemplo, para el primer caso si

$$X_1 = \begin{bmatrix} 1 & 1 \\ 1 & 2 \\ 1 & 1 \\ 1 & 3 \end{bmatrix}; \quad D^t = (0 \ 2),$$

$\lambda_1^t \theta = (1 \ 0 \ 0) \theta$ es estimable si

$$K_1^t = (1 \ 0), \quad K_1^t D = (1 \ 0) \begin{pmatrix} 0 \\ 2 \end{pmatrix} = 0.$$

Como $\lambda_1^t \theta = [K_1^t : K_1^t D] \theta$, entonces $\lambda_1^t \theta$ es estimable. En el segundo caso, $\lambda_2^t = (0 \ 1 \ 2)$ si $K_1^t = (0 \ 1)$ y $K_1^t D = (0 \ 1)(0 \ 2)^t = 2$, se observa que $\lambda_2^t = [K_1^t : K_1^t D]$, luego es estimable. En el tercer caso, $\lambda_3^t = (0 \ 1 \ 0)$, se observa que $K_1^t = (0 \ 1)$ y $K_1^t D = (0 \ 1)(0 \ 2)^t = 2$, teniendo en cuenta que λ_3^t es diferente de $[K_1^t : K_1^t D]$, encontrándose así que esta función no es estimable.

Método 3. Consiste en encontrar una matriz $C_{p \times (p-r)}$ de rango completo, es decir, $r(C) = (p-r)$ tal que $XC = 0$, entonces $\lambda^t \theta$ es estimable si y solo si $\lambda^t C = 0$.

Retomando el ejemplo,

$$XC = \begin{bmatrix} 1 & 1 & 2 \\ 1 & 2 & 4 \\ 1 & 1 & 2 \\ 1 & 3 & 6 \end{bmatrix} \begin{bmatrix} 0 \\ 2 \\ -1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix},$$

Observe que:

i) $[1 \ 0 \ 0][0 \ 2 \ -1]^t = 0$, luego es estimable.

ii) $[0 \ 1 \ 2][0 \ 2 \ -1]^t = 0$, luego es estimable.

iii) $[0 \ 1 \ 0][0 \ 2 \ -1]^t = 2$ es diferente de 0, entonces no es estimable.

Método 4. Consiste en obtener una g -inversa de $X^t X$, denotada por $(X^t X)^g$, entonces $\lambda^t \theta$ es estimable si y solo si $\lambda^t (X^t X)^g (X^t X) = \lambda^t$, es decir, $\lambda^t H = \lambda^t$, siendo $H = (X^t X)^g (X^t X) = X^l X = X^+ X$, en donde X^l es la inversa de mínimos cuadrados y X^+ es la inversa de Moore-Penrose de la matriz X .

Este último procedimiento es el más conocido dentro de los diferentes métodos presentados. Por su importancia, a continuación se realiza la prueba que soporta el método anterior.

Prueba.

$\Rightarrow$ Si $\lambda^t \theta$ es estimable, entonces $\lambda^t = a^t X$ para algún a y $\lambda^t H = \lambda^t (X^t X)^g (X^t X) = a^t X (X^t X)^g (X^t X) = a^t P_X X = a^t X = \lambda^t$.

$\Leftarrow$ Si $\lambda^t H = \lambda^t$, entonces $\lambda^t = \lambda^t (X^t X)^g (X^t X) = a^t X$, donde $a^t = \lambda^t (X^t X)^g X^t$, y λ^t pertenece al espacio fila de X ($\lambda^t \in \mathfrak{R}(X)$), luego λ^t es estimable.

Retomando el ejemplo,

$$(X^t X) = \begin{bmatrix} 4 & 7 & 14 \\ 7 & 15 & 30 \\ 14 & 30 & 60 \end{bmatrix}.$$

Una g -inversa es

$$(X^t X)^g = \frac{1}{11} \begin{bmatrix} 15 & -7 & 0 \\ -7 & 4 & 0 \\ 0 & 0 & 0 \end{bmatrix}.$$

Obteniéndose entonces que

- i) $(1 \ 0 \ 0)(X^t X)^g (X^t X) = (1 \ 0 \ 0)$, entonces es estimable.
- ii) $(0 \ 1 \ 2)(X^t X)^g (X^t X) = (0 \ 1 \ 2)$, entonces es estimable.
- iii) $(0 \ 1 \ 0)(X^t X)^g (X^t X)$ es diferente de $(0 \ 1 \ 0)$, por lo tanto, no es estimable.

Observación 3.1. Si $r(X) = p$, entonces la única g -inversa de $(X^t X)$ es $(X^t X)^{-1}$. De esta forma, $\lambda^t (X^t X)^{-1} (X^t X) = \lambda^t I = \lambda^t$, luego $\lambda^t \theta$ es estimable cualquiera sea la solución de θ .

Definición 3.2. Si $\lambda^t \theta$ es estimable y $a^t Y$ es el estimador lineal insesgado (ELI), el cual posee menor varianza entre todos los $ELIS$, entonces $a^t Y$ es el mejor ELI ($MELI$) de $\lambda^t \theta$.

De la anterior definición se sigue que

$$MELI(E(a^t Y)) = MELI(a^t X \theta) = MELI(\lambda^t \theta) = a^t Y,$$

observando que el espacio de estimación coincide con el que contiene todos los $MELIS$, es decir, $a^t Y$ pertenece al espacio de estimación si y solo si $a^t Y$ es el $MELI$ de su esperanza.

Observación 3.2. $MELI(\lambda^t \theta) = q^t X^t Y$ para algún q , luego $MELI(\lambda^t \theta) = a^t Y$, entonces a^t pertenece al espacio fila de (X^t) ($a \in R(X^t)$) si y solo si $a^t = q^t X^t$ para algún q .

Observación 3.3. $E(MELI(\lambda^t \theta)) = E(q^t X^t Y) = \lambda^t \theta$ para todo θ si y solo si $q^t X^t X \theta = \lambda^t \theta$ para todo θ , luego $q^t X^t X = \lambda^t$, resultado conocido como ecuaciones normales conjugadas (ENC). Si q^t satisface las ENC, entonces $MELI(\lambda^t \theta) = q^t X^t Y$.

Teorema 3.1. Si $\lambda^t \theta$ es estimable, entonces $MELI(\lambda^t \theta) = \lambda^t \theta^0$ para todo θ solución de las ecuaciones normales $X^t X \theta = X^t Y$.

Prueba.

Si $\lambda^t \theta$ es estimable, entonces existe q^t tal que $q^t X^t X = \lambda^t$ y, teniendo en cuenta las observaciones 3.2 y 3.3, se satisface que $MELI(\lambda^t \theta) = q^t X^t Y$.

Sea θ una solución al sistema de las ecuaciones normales (EN), $X^t X \theta = X^t Y$. Entonces, $q^t X^t Y = q^t X^t X \theta = \lambda^t \theta$, la cual satisface las ENC por lo que

$$MELI(\lambda^t \theta) = \lambda^t \theta^0 = \lambda^t (X^t X)^g X^t Y.$$

Como λ^t pertenece a $R(X^t)$, entonces $\lambda^t = a^t X$ y, así,

$$MELI(\lambda^t \theta) = a^t X (X^t X)^g X^t Y = a^t P_X Y = a^t Y$$

y

$$Var(MELI(\lambda^t \theta)) = Var(\lambda^t \hat{\theta}) = \lambda^t Var(\theta^0) \lambda = \lambda^t (X^t X)^g \lambda \sigma^2 = q^t \lambda \sigma^2.$$

Ejemplo 3.3. Suponga el modelo $y_{ij} = \mu + \tau_i + e_{ij}$, $i = 1, 2, 3$ y $j = 1, \dots, n_i$, con $n_1 = 3$, $n_2 = 2$ y $n_3 = 1$ y el supuesto de $e_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$.

Para este conjunto de datos, la matriz diseño está dada por

$$X = \begin{pmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{pmatrix}.$$

El modelo lineal expresado en forma matricial es

$$\begin{pmatrix} y_{11} \\ y_{12} \\ y_{13} \\ y_{21} \\ y_{22} \\ y_{31} \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} \mu + \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \tau_1 \\ \tau_2 \\ \tau_3 \end{pmatrix} + \begin{pmatrix} e_{11} \\ e_{12} \\ e_{13} \\ e_{21} \\ e_{22} \\ e_{31} \end{pmatrix}.$$

Las ecuaciones normales generadas a partir del anterior modelo son.

$$\begin{bmatrix} 6 & 3 & 2 & 1 \\ 3 & 3 & 0 & 0 \\ 2 & 0 & 2 & 0 \\ 1 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mu \\ \tau_1 \\ \tau_2 \\ \tau_3 \end{bmatrix} = \begin{bmatrix} Y_{..} \\ Y_{1.} \\ Y_{2.} \\ Y_{3.} \end{bmatrix}, \quad \mathbf{X}^t \mathbf{Y} = \begin{bmatrix} Y_{..} \\ Y_{1.} \\ Y_{2.} \\ Y_{3.} \end{bmatrix} = \begin{bmatrix} 504 \\ 300 \\ 172 \\ 32 \end{bmatrix}.$$

Dos g -inversas para este sistema son:

$$(\mathbf{X}^t \mathbf{X})_1^g = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & \frac{1}{3} & 0 & 0 \\ 0 & 0 & \frac{1}{2} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (\mathbf{X}^t \mathbf{X})_2^g = \begin{bmatrix} 1 & -1 & -1 & 0 \\ -1 & \frac{4}{3} & 1 & 0 \\ -1 & 1 & \frac{3}{2} & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}.$$

Entonces, las dos soluciones son:

$$\boldsymbol{\theta}_1^0 = (\mathbf{X}^t \mathbf{X})_1^g \mathbf{X}^t \mathbf{Y} = \begin{bmatrix} 0 \\ 100 \\ 86 \\ 32 \end{bmatrix} \quad y \quad \boldsymbol{\theta}_2^0 = (\mathbf{X}^t \mathbf{X})_2^g \mathbf{X}^t \mathbf{Y} = \begin{bmatrix} 32 \\ 68 \\ 54 \\ 0 \end{bmatrix}.$$

Se observa que $\mathbf{X} \boldsymbol{\theta}_1^0 = \mathbf{X} \boldsymbol{\theta}_2^0$. Si $\tau_1 - \tau_2$ es estimable, entonces $\tau_1 - \tau_2 = (0 \ 1 \ -1 \ 0) [\mu \ \tau_1 \ \tau_2 \ \tau_3]^t = \boldsymbol{\lambda}^t \boldsymbol{\theta}$.

De las EN

$$\begin{array}{rrcrcl} 6\mu & +3\tau_1 & +2\tau_2 & +\tau_3 & = Y_{..} \\ 3\mu & +3\tau_1 & & & = Y_{1.} \\ 2\mu & & +2\tau_2 & & = Y_{2.} \\ \mu & & & +\tau_3 & = Y_{3.} \end{array} \quad (3.8)$$

Del sistema (3.8), en la ecuación dos se observa que

$$\mu + \tau_1 = \frac{Y_{1.}}{3}. \quad (3.9)$$

Del mismo sistema, en la ecuación tres se obtiene

$$\mu + \tau_2 = \frac{Y_{2.}}{2}. \quad (3.10)$$

Restando (3.9) de (3.10) se encuentra $\tau_1 - \tau_2 = \frac{Y_{1.}}{3} - \frac{Y_{2.}}{2}$, de tal forma que

$$\begin{aligned} MELI(\tau_1 - \tau_2) &= \hat{\tau}_1 - \hat{\tau}_2 = \mathbf{q}^t \mathbf{X}^t \mathbf{Y} = \left(0 \ \frac{1}{3} \ -\frac{1}{2} \ 0 \right) \mathbf{X}^t \mathbf{Y} = \frac{Y_{1.}}{3} - \frac{Y_{2.}}{2} \\ &= \bar{Y}_{1.} - \bar{Y}_{2.} \end{aligned}$$

y

$$\begin{aligned}
Var(MELI(\tau_1 - \tau_2)) &= Var(\hat{\tau}_1 - \hat{\tau}_2) = \mathbf{q}^t \lambda \sigma^2 \\
&= \mathbf{q}^t \mathbf{X}^t \mathbf{X} \mathbf{q} \sigma^2 = Var(\mathbf{q}^t \mathbf{X}^t \mathbf{Y}) = \mathbf{q}^t \lambda \sigma^2 \\
&= \left(0 \quad \frac{1}{3} \quad -\frac{1}{2} \quad 0\right) [0 \quad 1 \quad -1 \quad 0]^t \sigma^2 = \left(\frac{5}{6}\right) \sigma^2.
\end{aligned}$$

La suma de cuadrados asociada a esta diferencia está dada por

$$SC(MELI(\tau_1 - \tau_2)) = SC(\mathbf{q}^t \mathbf{X}^t \mathbf{Y}) = SC(\mathbf{a}^t \mathbf{Y}) = \frac{(\mathbf{a}^t \mathbf{Y})^2}{\mathbf{a}^t \mathbf{a}} = \frac{(\bar{Y}_1 - \bar{Y}_2)^2}{\frac{5}{6}}.$$

Por otro lado, si

$$SC\left(\frac{Y_{1.}}{3}\right) = SC\left\{\left(\frac{1}{3}(1 \ 1 \ 1 \ 0 \ 0 \ 0)\mathbf{Y}\right)\right\} = \frac{\left(\frac{Y_{1.}}{3}\right)^2}{\mathbf{a}^t \mathbf{a}} = \frac{\left(\frac{Y_{1.}^2}{9}\right)}{\frac{1}{3}} = \frac{Y_{1.}^2}{3},$$

entonces

$$E\left[SC\left(\frac{Y_{1.}}{3}\right)\right] = \sigma^2 + SC\left(\frac{Y_{1.}}{3}\right) = \sigma^2 + \frac{(3\mu + 3\tau_1)^2}{3} = \sigma^2 + 3(\mu + \tau_1)^2.$$

Se observa de este resultado que la hipótesis de interés es $H_0 : \mu + \tau_1 = 0$. La forma directa de encontrar el valor esperado de la respectiva suma de cuadrados se obtiene haciendo $Y_{1.} = Y_{11} + Y_{12} + Y_{13} = \mu + \tau_1 + e_{11} + \mu + \tau_1 + e_{12} + \mu + \tau_1 + e_{13} = 3\mu + 3\tau_1 + e_{1.}$ y $Y_{1.}^2 = (3\mu + 3\tau_1 + e_{1.})^2 = 9(\mu + \tau_1)^2 + 6e_{1.}(\mu + \tau_1) + e_{1.}^2$.

Calculando el valor esperado de $Y_{1.}^2$ y suponiéndose que $E(e_{ij}^2) = \sigma^2$, se encuentra que

$$E\left[SC\left(\frac{Y_{1.}}{3}\right)\right] = \sigma^2 + 3(\mu + \tau_1)^2.$$

3.3.2. Transformaciones lineales y estimabilidad en modelos superparametrizados

3.3.2.1. Modelo con restricción paramétrica tipo Σ

El modelo Σ es un modelo lineal superparametrizado con restricción paramétrica de tipo “suma igual a cero” y se presenta como

$$\mathbf{Y} = \mathbf{Z}\boldsymbol{\theta} + \mathbf{e}, \quad (3.11)$$

donde $\mathbf{Z}_{n \times k}$ es una matriz conocida de rango completo, $\boldsymbol{\theta}_{k \times 1}$ es un vector de parámetros desconocidos y $\mathbf{Y}_{n \times 1}$ y $\mathbf{e}_{n \times 1}$ se definen como en el modelo lineal superparametrizado (3.1).

Se concentra ahora la atención en el modelo con restricción del tipo Σ presentado anteriormente, el cual es una representación alternativa del modelo superparametrizado. Esta reparametrización busca transformaciones lineales de los parámetros de tal forma que el espacio columna de la matriz $Z_{n \times k}(\mathcal{C}(Z))$ en (3.11) sea idéntico al espacio columna de la matriz $X_{n \times p}$ en (3.1), denotado por $\mathcal{C}(X)$.

Las transformaciones que conllevan a la superparametrización del modelo se soportan teóricamente en los siguientes teoremas.

Teorema 3.2. *Si Z es una matriz tal que el espacio columna de Z es idéntico con el espacio columna de X del modelo general $Y = X\theta + e$, entonces un modo alternativo de expresar el modelo (3.1) es $Y = Z\theta + e$. Además, la correspondencia entre funciones paramétricas insesgadas de las correspondientes funciones estimables son funciones lineales idénticas de las observaciones en los dos modelos.*

Teorema 3.3. *Si en el modelo (3.1) se introduce la transformación paramétrica $\theta = \tau\gamma$, donde la matriz τ es tal que los espacios columnas de las matrices X y $X\tau$ son idénticos, con la matriz τ no singular, entonces las siguientes condiciones se cumplen:*

a) El modelo (3.1) puede describirse de la siguiente forma:

$$Y = X\theta + e = (X\tau)\gamma + e. \quad (3.12)$$

b) Hay una correspondencia uno a uno entre las funciones estimables de los modelos (3.1) y (3.12).

c) Los MELI de las correspondientes funciones estimables son idénticos.

Teorema 3.4. *Un modelo de las hipótesis lineales que no sea de rango completo puede expresarse siempre como uno de rango completo sobre cualquier conjunto deseado de k funciones estimables linealmente independientes, donde k es el rango de la matriz asociada al modelo.*

Las pruebas de los teoremas anteriores se pueden consultar en Zyskind (1980). Basados en las anteriores ideas sobre estimabilidad, es posible considerar algunos métodos alternativos para la construcción de un conjunto generador L de funciones estimables, los cuales son presentados a partir de los datos del ejemplo 3.1.

Ejemplo 3.4. *Para los datos del ejemplo (3.1), $\theta = (\mu, \alpha_1, \alpha_2, \beta_1, \beta_2, \beta_3, \gamma_{11}, \gamma_{12}, \gamma_{13}, \gamma_{21}, \gamma_{22}) \in \mathcal{R}^{11}$. Si la reparametrización consiste en eliminar las columnas de X correspondientes a los parámetros $\alpha_2, \beta_3, \gamma_{12}, \gamma_{13}, \gamma_{21}$ y γ_{22}*

(equivale a colocar $\alpha_2 = \beta_3 = \gamma_{12} = \gamma_{13} = \gamma_{21} = \gamma_{22} = 0$), entonces la matriz diseño presentada en el ejemplo 3.1 se puede escribir como:

$$Z = \begin{pmatrix} 1 & 1 & 1 & 0 & 1 \\ 1 & 1 & 1 & 0 & 1 \\ 1 & 1 & 0 & 1 & 0 \\ 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 & 0 \end{pmatrix}.$$

Y el modelo asociado es (3.11), en donde $\boldsymbol{\theta} = (\delta_1, \delta_2, \delta_3, \delta_4, \delta_5) \in \mathbb{R}^5$. En este caso,

$$\hat{\boldsymbol{\theta}} = (Z^t Z)^{-1} Z^t Y = \begin{pmatrix} 10 & 5 & 4 & 4 & 2 \\ 5 & 5 & 2 & 1 & 2 \\ 4 & 2 & 4 & 0 & 2 \\ 4 & 1 & 0 & 4 & 0 \\ 2 & 2 & 2 & 0 & 2 \end{pmatrix}^{-1} \begin{pmatrix} y_{\dots} \\ y_{1\cdot\cdot} \\ y_{\cdot 1\cdot} \\ y_{\cdot 2\cdot} \\ y_{11\cdot} \end{pmatrix}$$

$$\begin{pmatrix} 11/6 & -4/3 & -11/6 & -3/2 & 4/3 \\ -4/3 & 4/3 & 4/3 & 1 & -4/3 \\ -11/6 & 4/3 & 7/3 & 3/2 & -11/6 \\ -3/2 & 1 & 3/2 & 3/2 & -1 \\ 4/3 & -4/3 & -11/6 & -1 & 7/3 \end{pmatrix} \begin{pmatrix} 90 \\ 30 \\ 28 \\ 56 \\ 16 \end{pmatrix} = \begin{pmatrix} 11 \\ -8 \\ -5 \\ 5 \\ 10 \end{pmatrix},$$

pero como $Y = X\boldsymbol{\theta} + e = ZT\boldsymbol{\theta} + e = Z\boldsymbol{\theta} + e$, entonces $X = ZT$, donde

$$T = (Z^t Z)^{-1} Z^t X = \begin{pmatrix} 1 & 0 & 1 & 0 & 0 & 1 & 0 & -1 & 1 & 0 & 1 \\ 0 & 1 & -1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & -1 \\ 0 & 0 & 0 & 1 & 0 & -1 & 0 & 1 & -1 & 1 & -1 \\ 0 & 0 & 0 & 0 & 1 & -1 & 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 & 0 & -1 & 1 \end{pmatrix}.$$

Finalmente, se observa que el vector de parámetros en el modelo reparametrizado se puede escribir en términos de los parámetros del modelo superparametrizado, realizando la siguiente transformación:

$$\dot{\theta} = T\theta = \begin{pmatrix} \mu + \alpha_2 + \beta_3 - \gamma_{12} + \gamma_{13} + \gamma_{22} \\ \alpha_1 - \alpha_2 + \gamma_{12} - \gamma_{22} \\ \beta_1 - \beta_3 + \gamma_{12} - \gamma_{13} + \gamma_{21} - \gamma_{22} \\ \beta_2 - \beta_3 + \gamma_{12} - \gamma_{13} \\ \gamma_{11} - \gamma_{12} - \gamma_{21} + \gamma_{22} \end{pmatrix}.$$

3.4. Modelos lineales particionados y sumas de cuadrados asociadas

En esta sección, se parte del modelo particionado en k partes ortogonales para obtener, a partir de estas particiones, los diferentes tipos de hipótesis y sumas de cuadrados asociadas.

3.4.1. Modelo particionado en dos partes

Se supone que $Y = F(X_1^1, \dots, X_p^1, X_1^2, \dots, X_q^2)$ y se tiene interés en evaluar si $X_1 = (X_1^1, \dots, X_p^1)$ contribuye a explicar a Y una vez que se tiene a $X_2 = (X_1^2, \dots, X_q^2)$ en el modelo o también si $Y = F(X_1/X_2)$, es decir, si $X_1^1, \dots, X_p^1$ explica a Y , dado que están incluidos en el modelo $X_1^2, \dots, X_q^2$. En este caso se puede ajustar los modelos

$$Y = X_1\theta_1 + X_2\theta_2 \quad (3.13)$$

ó

$$Y = X_2\theta_2 + X_1\theta_1. \quad (3.14)$$

El orden en que se escribe el modelo es bien importante. Los órdenes de los respectivos valores de parámetros son θ_1 de tamaño $p \times 1$ y θ_2 de tamaño $q \times 1$. Si X y θ son particionados de la forma $(X_1 : X_2)$ y $\theta^t = (\theta_1^t : \theta_2^t)$, respectivamente, y se considera el modelo

$$Y = X_2\theta_2 + e, \quad (3.15)$$

entonces

$$R(\theta_2) = (\theta_2^0)^t X_2^t Y, \quad (3.16)$$

donde θ_2^0 es una solución al sistema $X_2^t X_2 \theta_2 = X_2^t Y$.

De la misma manera, se define

$$R(\theta_1/\theta_2) = R(\theta_1, \theta_2) - R(\theta_2), \quad (3.17)$$

El modelo (3.13) tiene las siguientes ecuaciones normales:

$$X_1^t X_1 \hat{\theta}_1 + X_1^t X_2 \hat{\theta}_2 = X_1^t Y \quad (3.18)$$

$$X_2^t X_1 \hat{\theta}_1 + X_2^t X_2 \hat{\theta}_2 = X_2^t Y. \quad (3.19)$$

De la ecuación (3.18), se sigue que $\hat{\theta}_1 = (X_1^t X_1)^{-1} (X_1^t Y - X_1^t X_2 \hat{\theta}_2)$. Sustituyendo este resultado en la ecuación (3.19), se tiene

$$X_2^t X_1 [(X_1^t X_1)^{-1} (X_1^t Y - X_1^t X_2 \hat{\theta}_2)] + X_2^t X_2 \hat{\theta}_2 = X_2^t Y. \quad (3.20)$$

Haciendo los desarrollos algebraicos apropiados, (3.20) se puede escribir

$$\begin{aligned} -X_2^t X_1 (X_1^t X_1)^{-1} X_1^t X_2 \hat{\theta}_2 + X_2^t X_2 \hat{\theta}_2 &= X_2^t Y - X_2^t X_1 (X_1^t X_1)^{-1} X_1^t Y \\ X_2^t [I - X_1 (X_1^t X_1)^{-1} X_1^t] X_2 \hat{\theta}_2 &= X_2^t [I - X_1 (X_1^t X_1)^{-1} X_1^t] Y \\ X_2^t (I - P_1) X_2 \hat{\theta}_2 &= X_2^t (I - P_1) Y, \end{aligned} \quad (3.21)$$

donde $P_1 = X_1 (X_1^t X_1)^{-1} X_1^t$.

Las ecuaciones normales obtenidas en (3.21) se conocen como ecuaciones normales reducidas (ENR) asociadas con $X_2 \theta_2$ después de tener $X_1 \theta_1$ en el modelo. Observe que $[I - P_1]Y$ es el vector de residuales cuando se ajusta el modelo $E(Y) = X_1 \theta_1$ y, además, las columnas $[I - P_1]X_2$ en (3.21) son vectores de residuales cuando se ajustan las columnas de X_2 como vector de respuestas. Las estimaciones de $\hat{\theta}_2$ en el modelo reducido se obtienen mediante:

$$\hat{\theta}_2 = [X_2^t (I - P_1) X_2]^{-1} X_2^t [I - P_1] Y,$$

La suma de cuadrados de los residuales es

$$SCE(\hat{\theta}_2) = Y^t (I - P_1) Y - \hat{\theta}_2^t X_2^t (I - P_1) Y. \quad (3.22)$$

En (3.22), $Y^t (I - P_1) Y$ es la mínima suma de cuadrados para ajustar el modelo $Y = X_1 \theta_1$. La tabla 3.3 resume el análisis de varianza para este modelo.

Tabla 3.3: ANOVA para el modelo particionado $Y = X_1 \theta_1 + X_2 \theta_2$

Causas de variación	gl	SC
$X_1 : X_1 \theta_1$	r_1	$Y^t P_1 Y$
$X_2/X_1 : X_2 \theta_2$ después de $X_1 \theta_1$	$r_{12} - r_1$	$Y^t (P_{12} - P_1) Y$
$I/X_1 X_2 : \text{residual}$	$n - r_{12}$	$Y^t (I - P_{12}) Y$
Total	n	$Y^t Y$

donde $r_1 = \text{ran}(X_1)$ y $r_{12} = \text{ran}(X_1 : X_2)$.

Observación 3.4. Si hay ortogonalidad se satisface que

$$Y^t(P_{12} - P_1)Y = Y^t P_2 Y, \quad \forall Y.$$

y

$$Y^t(P_{12} - P_2)Y = Y^t P_1 Y, \quad \forall Y,$$

luego $P_{12} = P_1 + P_2$ ó también $X_1^t P_{12} X_2 = X_1^t P_1 X_2 + X_1^t P_2 X_2$, lo cual implica que $X_1^t X_2 = \mathbf{0}$.

Observación 3.5. Un caso particular del modelo particionado es considerar el modelo $Y = \mathbf{1}\mu + X\theta$, donde $\mathbf{1}^t = (1, 1, \dots, 1)$, luego el modelo tiene la forma $Y = X_1\theta_1 + X_2\theta_2$, con $P_1 = \mathbf{1}(\mathbf{1}^t \mathbf{1})^{-1} \mathbf{1}^t = \frac{1}{n} \mathbf{1} \mathbf{1}^t = \frac{1}{n} J_n$.

Las ENR están dadas por

$$X^t \left(I - \frac{1}{n} J_n \right) X \hat{\theta}_2 = X^t \left(I - \frac{1}{n} J_n \right) Y. \quad (3.23)$$

La $SC(\mu) = Y^t \frac{1}{n} J_n Y$, esta suma de cuadrados es conocida como el factor de corrección.

Ejemplo 3.5. Para los datos del ejemplo 3.3, se tiene el modelo: $Y = X_1\mu + X_2\tau + \epsilon$. Haciendo $X = [X_1 : X_2]$ y $\theta^t = [\theta_1^t : \theta_2^t] = [\mu, \tau_1, \tau_2, \tau_3]$, las ENR quedan de la forma

$$X_2^t (I - P_1) X_2 \theta_2 = X_2^t (I - P_1) Y,$$

donde $\theta_2^t = (\tau_1, \tau_2, \tau_3)^t$ se estima solucionando el siguiente sistema:

$$\frac{3}{10} \begin{pmatrix} 8 & -4 & -4 \\ -4 & 7 & -3 \\ -4 & -3 & 7 \end{pmatrix} \begin{pmatrix} \tau_1 \\ \tau_2 \\ \tau_3 \end{pmatrix} = \frac{3}{10} \begin{pmatrix} -32 \\ 6 \\ 26 \end{pmatrix}.$$

$$\text{Luego } \hat{\theta}_2^0 = [X_2^t (I - P_1) X_2]^{-1} X_2^t (I - P_1) Y = \begin{pmatrix} 0 \\ 3 \\ 5 \end{pmatrix}.$$

Con la finalidad de obtener la tabla de análisis de varianza asociada a los datos del ejemplo 3.3, los grados de libertad y las sumas de cuadrados asociadas a cada una de las causas de variación, se deben tener en cuenta en el siguiente procedimiento:

- i. Con base en el modelo particionado se encuentra que $r_1 = \text{ran}(X_1) = 1$ y $r_{12} = \text{ran}(X_{12}) = 3$.

ii. Se obtienen las sumas de cuadrados realizando los siguientes cálculos

$$\begin{aligned} Y^t P_1 Y &= Y^t \frac{1}{n} J_{6 \times 6} Y = \frac{1}{n} \left(\sum_i \sum_j y_{ij} \right)^2 \\ &= \frac{y_{..}^2}{6} = \frac{(504)^2}{6} = 42336, \end{aligned}$$

con $n = \sum_{i=1}^3 n_i$, la cual se conoce como suma de cuadrados asociado con la media.

De forma análoga, se obtiene la suma de cuadrados asociada a los tratamientos ajustados por la media ($SCTr_{CM}$), o sea,

$$\begin{aligned} SCTr_{CM} &= Y^t (P_{12} - P_1) Y = Y^t \left\{ [X_{12} (X_{12}^t X_{12})]^{-1} X_{12}^t - \frac{1}{n} J_{n \times n} \right\} Y \\ &= Y^t \begin{bmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 & 0 & 0 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 & 0 & 0 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{2} & \frac{1}{2} & 0 \\ 0 & 0 & 0 & \frac{1}{2} & \frac{1}{2} & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} Y - \frac{y_{..}^2}{6} \\ &= \sum_{i=1}^3 \frac{1}{n_i} y_{i.}^2 - \frac{y_{..}^2}{6} \\ &= \frac{1}{3} (300)^2 + \frac{1}{2} (172)^2 + (32)^2 - \frac{(504)^2}{6} = 3480. \end{aligned}$$

Finalmente, se obtiene la suma de cuadrados del error

$$\begin{aligned} SCE &= Y^t (I - P_{12}) Y = Y^t Y - Y^t P_{12} Y \\ &= \sum_{i=1}^3 \sum_{j=1}^{n_i} y_{ij}^2 - \sum_{i=1}^3 \frac{1}{n_i} y_{i.}^2. \end{aligned}$$

Por lo tanto, la tabla 3.4 corresponde al análisis de varianza para el modelo propuesto en el ejemplo 3.3.

Observación 3.6. Como se satisface que $(I - P_1) = [I - X_1 (X_1^t X_1)^{-1} X_1^t]$ es idempotente, por lo tanto se puede escribir

$$X_2^t (I - P_1) (I - P_1) X_2 \hat{\theta}_2 = X_2^t (I - P_1) Y. \quad (3.24)$$

Haciendo $A = X_2^t (I - P_1)$, se tiene en (3.24) el sistema de $A^t A \theta = A^t Y$, que tiene las características de las ecuaciones normales, por tanto, es un sistema consistente.

Tabla 3.4: Tabla de análisis de varianza del modelo particionado para los datos del ejemplo 3.3

Causas de variación	gl	SC
Media ($X_1\theta_1$)	1	$\frac{y^2}{6} = 42336$
Tratamientos ($X_2\theta_2/X_1\theta_1$)	2	$\sum_{i=1}^3 \frac{1}{n_i} y_{i.}^2 - \frac{y^2}{6} = 3480$
Residual	3	$\sum_{i=1}^3 \sum_{j=1}^{n_i} y_{ij}^2 - \sum_{i=1}^3 \frac{1}{n_i} y_{i.}^2$
Total	6	$\sum_{i=1}^3 \sum_{j=1}^{n_i} y_{ij}^2$

Teorema 3.5. Una función lineal paramétrica $\lambda^t \theta_2$ se dice que es estimable en el modelo $Y = X_1\theta_1 + X_2\theta_2$ si y solamente si $\lambda^t \in \mathcal{C}(X_2^t(I - P_1)X_2)$.

3.4.2. Modelo particionado en tres partes

Considere el modelo $Y = X_1\theta_1 + X_2\theta_2 + X_3\theta_3$, en el cual se tienen $3! = 6$ posibles análisis de varianza, los cuales dependen de la forma como se ordenen los términos que entran en el modelo, estos son:

$$\begin{array}{cccccc}
 X_1 & X_1 & X_2 & X_2 & X_3 & X_3 \\
 X_2/X_1 & X_3/X_1 & X_1/X_2 & X_3/X_2 & X_1/X_3 & X_2/X_3 \\
 X_3/X_1X_2 & X_2/X_1X_3 & X_3/X_1X_2 & X_1/X_2X_3 & X_2/X_1X_3 & X_1/X_2X_3 \\
 I/X_1X_2X_3 & I/X_1X_2X_3 & I/X_1X_2X_3 & I/X_1X_2X_3 & I/X_1X_2X_3 & I/X_1X_2X_3
 \end{array}$$

Cualquier suma de cuadrados es obtenida usando la reducción en suma de cuadrados, por ejemplo,

$$\begin{aligned}
 SC(X_3/X_1, X_2) &= R(\theta_3/\theta_1, \theta_2) \\
 &= R(\theta_1, \theta_2, \theta_3) - R(\theta_1, \theta_2) \\
 &= Y^t(P_{123} - P_{12})Y,
 \end{aligned}$$

donde, por ejemplo,

$$P_{123} = (X_1 : X_2 : X_3)[(X_1 : X_2 : X_3)^t(X_1 : X_2 : X_3)]^{-1}(X_1 : X_2 : X_3)^t.$$

Ejemplo 3.6. Hinkelman y Kempthorne (1994) consideran un modelo a dos vías de clasificación sin interacción, es decir,

$$Y_{ijk} = \mu + \alpha_i + \beta_j + \epsilon_{ijk}, \quad (3.25)$$

donde $i = 1, \dots, r$, $j = 1, \dots, c$ y $k = 1, \dots, n_{ij}$, con $n_{ij} \geq 0$. Matricialmente se puede escribir

$$Y = \mathbf{1}\mu + X_r\tau + X_c\beta, \quad (3.26)$$

donde X_r y X_c son matrices de incidencia. En el modelo (3.26) se tienen únicamente dos análisis de varianza

$$\begin{array}{ccc} \mathbf{1} & & \mathbf{1} \\ \mathbf{X}_r/\mathbf{1} & & \mathbf{X}_c/\mathbf{1} \\ \mathbf{X}_c/\mathbf{1}, \mathbf{X}_r & y & \mathbf{X}_r/\mathbf{1}, \mathbf{X}_c \\ \mathbf{I}/\mathbf{1}, \mathbf{X}_r, \mathbf{X}_c & & \mathbf{I}/\mathbf{1}, \mathbf{X}_r, \mathbf{X}_c \end{array}$$

En el cálculo de las sumas de cuadrados se satisface

$$SC(\mathbf{X}_c/\mathbf{1}, \mathbf{X}_r) = SC(\mathbf{1}, \mathbf{X}_c, \mathbf{X}_r) - SC(\mathbf{1}, \mathbf{X}_r) = SC(\mathbf{X}_c/\mathbf{1}).$$

El anterior resultado es equivalente a

$$SC(\mathbf{X}_r/\mathbf{1}, \mathbf{X}_c) = SC(\mathbf{X}_r/\mathbf{1}).$$

Las sumas de cuadrados en términos de proyectores ortogonales son obtenidas como

$$\mathbf{Y}^t(\mathbf{P}_{rc} - \mathbf{P}_r)\mathbf{Y} = \mathbf{Y}^t(\mathbf{P}_c - \mathbf{P}_1)\mathbf{Y}, \quad (3.27)$$

donde $\mathbf{P}_1 = \mathbf{1}(\mathbf{1}^t\mathbf{1})^{-1}\mathbf{1}^t$ es el proyector ortogonal en el espacio columna de $\mathbf{1}$ ($\mathcal{C}(\mathbf{1})$), $\mathbf{P}_r$ son el proyector ortogonal en el espacio columna de $(\mathbf{1}:\mathbf{X}_r)$, ($\mathcal{C}(\mathbf{1}:\mathbf{X}_r)$) y $\mathbf{P}_{rc}$ es el proyector ortogonal en el espacio columna de $(\mathbf{1}:\mathbf{X}_r:\mathbf{X}_c)$, ($\mathcal{C}(\mathbf{1}:\mathbf{X}_r:\mathbf{X}_c)$).

En (3.27), para que la igualdad se satisfaga para todo $\mathbf{Y}$ se necesita que $\mathbf{P}_{rc} - \mathbf{P}_r = \mathbf{P}_c - \mathbf{P}_1$, dando

$$\begin{aligned} \mathbf{X}_r^t(\mathbf{P}_{rc} - \mathbf{P}_r)\mathbf{X}_c &= \mathbf{X}_r^t(\mathbf{P}_c - \mathbf{P}_1)\mathbf{X}_c \\ \mathbf{X}_r^t\mathbf{P}_{rc}\mathbf{X}_c - \mathbf{X}_r^t\mathbf{P}_r\mathbf{X}_c &= \mathbf{X}_r^t\mathbf{P}_c\mathbf{X}_c - \mathbf{X}_r^t\mathbf{P}_1\mathbf{X}_c. \end{aligned} \quad (3.28)$$

Reemplazando por las matrices asociadas al proyector, se satisface que el lado izquierdo en (3.28) es $\mathbf{X}_r^t\mathbf{X}_c - \mathbf{X}_r^t\mathbf{X}_c = \mathbf{0}$ y el lado derecho es $\mathbf{X}_r^t\mathbf{X}_c - \mathbf{X}_r^t\mathbf{P}_1\mathbf{X}_c$. De esta manera, $\mathbf{X}_r^t\mathbf{X}_c = \frac{1}{n}(\mathbf{X}_r^t\mathbf{1})(\mathbf{1}^t\mathbf{X}_c)$ es el número de observaciones para cada combinación fila-columna, entonces se dice que hay una única ANOVA si hay proporcionalidad en las celdas.

3.4.3. Modelo particionado en k partes ordenadas

Al particionar el modelo (3.1) se satisface que

$$\begin{aligned} \mathbf{X}_1^t\mathbf{X}_1\mathbf{B}_1 &= \mathbf{X}_1^t \text{ y } \mathbf{P}_1 = \mathbf{X}_1\mathbf{B}_1 = \mathbf{X}_1(\mathbf{X}_1^t\mathbf{X}_1)^{-}\mathbf{X}_1^t \\ \mathbf{X}_{12}^t\mathbf{X}_{12}\mathbf{B}_{12} &= \mathbf{X}_{12}^t \text{ y } \mathbf{P}_{12} = \mathbf{X}_{12}\mathbf{B}_{12} = \mathbf{X}_{12}(\mathbf{X}_{12}^t\mathbf{X}_{12})^{-}\mathbf{X}_{12}^t \\ \mathbf{X}_{123}^t\mathbf{X}_{123}\mathbf{B}_{123} &= \mathbf{X}_{123}^t \text{ y } \mathbf{P}_{123} = \mathbf{X}_{123}\mathbf{B}_{123} = \mathbf{X}_{123}(\mathbf{X}_{123}^t\mathbf{X}_{123})^{-}\mathbf{X}_{123}^t \\ &\vdots \\ \mathbf{X}_{1\dots k}^t\mathbf{X}_{1\dots k}\mathbf{B}_{1\dots k} &= \mathbf{X}_{1\dots k}^t \text{ y } \mathbf{P}_{1\dots k} = \mathbf{X}_{1\dots k}\mathbf{B}_{1\dots k} = \mathbf{X}_{1\dots k}(\mathbf{X}_{1\dots k}^t\mathbf{X}_{1\dots k})^{-}\mathbf{X}_{1\dots k}^t, \end{aligned}$$

donde $P_1, P_{12}, \dots, P_{12\dots k}$ son matrices simétricas e idempotentes y, además, $P_{12\dots i}$ es el proyector ortogonal en el espacio columna de $X_{12\dots i}$ ($\mathcal{C}(X_{12\dots i})$), $i = 1, 2, \dots, k$.

De esta manera, el modelo se puede escribir como

$$Y = P_1 Y + (P_{12} - P_1)Y + \dots + (P_{12\dots k} - P_{12\dots k-1})Y + (I - P_{12\dots k})Y, \quad (3.29)$$

donde cada término es ortogonal a todas las demás componentes de la descomposición y, además, la matriz asociada a cada componente es simétrica e idempotente.

El análisis de varianza asociado con el modelo particionado se presenta en la tabla 3.5.

Tabla 3.5: Tabla de análisis de varianza asociada al modelo particionado (3.29)

Causas de variación	gl	SC
$X_1 \theta_1$	$r(X_1)$	$Y^t P_1 Y$
$X_2 \theta_2 / X_1 \theta_1$	$r(X_{12}) - r(X_1)$	$Y^t (P_{12} - P_1) Y$
$X_3 \theta_3 / X_1 \theta_1 + X_2 \theta_2$	$r(X_{123}) - r(X_{12})$	$Y^t (P_{123} - P_{12}) Y$
$\vdots$	$\vdots$	$\vdots$
$X_k \theta_k / X_1 \theta_1 + \dots + X_{k-1} \theta_{k-1}$	$r(X_{12\dots k}) - r(X_{12\dots k-1})$	$Y^t (P_{12\dots k} - P_{12\dots k-1}) Y$
$I / X_1 \theta_1 + \dots + X_k \theta_k$	$n - r(X_{12\dots k})$	$Y^t (I - P_{12\dots k}) Y$
Total	n	$Y^t Y$

Desde este punto de vista, computacionalmente las sumas de cuadrados se obtienen secuencialmente ajustando los modelos:

$$Y = X_1 \theta_1 + d_1$$

$$Y = X_1 \theta_1 + X_2 \theta_2 + d_{12}$$

$$\vdots$$

$$Y = X_1 \theta_1 + X_2 \theta_2 + \dots + X_k \theta_k + d_{12\dots k}.$$

Observación 3.7. Cada modelo va a tener $k!$ análisis de varianza, una para cada orden posible en el que se arreglan las k -componentes. Si hay ortogonalidad, o sea, si $X_i^t X_j = 0$, se tiene un único análisis de varianza.

Ejemplo 3.7. Suponga el siguiente conjunto de datos de la tabla 3.6, donde se caracteriza un modelo a dos vías sin interacción.

La matriz diseño para este conjunto de datos asociada al modelo (3.1) está dada por

$$X = (X_1 : X_2 : X_3) = (\mathbf{1}_{20} : I_5 \otimes \mathbf{1}_4 : \mathbf{1}_5 \otimes I_4).$$

Tabla 3.6: Datos ficticios para un modelo de clasificación a dos vías sin interacción

Factor A	Factor B			
	1	2	3	4
1	3.5	2.6	2.9	3.6
2	2.8	1.9	2.1	3.4
3	3.8	2.9	3.2	3.2
4	4.1	4.9	4.2	4.3
5	2.7	1.6	1.8	2.5

Para este arreglo, se ajustan secuencialmente los siguientes modelos:

1. $Y_{ij} = \mu + e_{ij}$, $i = 1, 2, \dots, 5$, $j = 1, 2, 3, 4$. En este caso,

$$Y = (3.5, 2.6, 2.9, 3.6, 2.8, 1.9, 2.1, 3.4, 3.8, 2.9, 3.2, 3.2, 4.1, 4.9, 4.2, 4.3, 2.7, 1.6, 1.8, 2.5)^t,$$

$$P_1 = X_1(X_1^t X_1)^{-} X_1^t = \frac{1}{20} J_{20},$$

donde J_{20} es una matriz de unos de tamaño 20×20 y $X_1 = \mathbf{1}_{20}$ es un vector de unos de tamaño 20×1 .

La suma de cuadrados asociada a este modelo es:

$$R(\mu) = Y^t X_1 (X_1^t X_1)^{-} X_1^t Y = 192.2$$

y la suma de cuadrados del error asociada a este caso es:

$$SCE = SCT_{CM} - R(\mu) = 207.42 - 192.2 = 15.22$$

2. $Y_{ij} = \mu + \tau_i + e_{ij}$, $i = 1, 2, \dots, 5$, $j = 1, 2, 3, 4$, con

$$P_{12} = X_{12}(X_{12}^t X_{12})^{-} X_{12}^t = \frac{1}{4} (I_5 \otimes J_4),$$

donde I_5 una matriz identidad de tamaño 5×5 , J_4 una matriz de unos de tamaño 4×4 y $X_{12} = (\mathbf{1}_{20} : I_5 \otimes \mathbf{1}_4)$.

La suma de cuadrados asociada a este modelo es:

$$R(\mu, \tau) = Y^t X_{12} (X_{12}^t X_{12})^{-} X_{12}^t Y = 203.66$$

y la suma de cuadrados asociada al efecto τ (factor A) es

$$R(\tau/\mu) = R(\mu, \tau) - R(\mu) = 203.66 - 192.2 = 11.46.$$

En este caso, la suma de cuadrados asociada al error para este modelo está dada por

$$SCE = SCT_{CM} - R(\mu, \tau) = 207.42 - 203.66 = 3.76.$$

Finalmente, se puede ajustar el modelo

3. $Y_{ij} = \mu + \tau_i + \beta_j + e_{ij}$, $i = 1, 2, \dots, 5$, $j = 1, 2, 3, 4$, con

$$P_{123} = X_{123}(X_{123}^t X_{123})^{-1} X_{123}^t,$$

donde $X_{123} = (\mathbf{1}_{20} : I_5 \otimes \mathbf{1}_4 : \mathbf{1}_5 \otimes I_4)$. La suma de cuadrados asociada a este modelo está dada por

$$R(\mu, \tau, \beta) = Y^t X_{123} (X_{123}^t X_{123})^{-1} X_{123}^t Y = 205.35,$$

y la suma de cuadrados asociada al efecto β (factor B) es:

$$R(\beta/\mu, \tau) = R(\mu, \tau, \beta) - R(\mu, \tau) = 205.35 - 203.66 = 1.69.$$

4. $SCE = Y^t Y - R(\mu, \tau, \beta) = 207.42 - 205.35 = 2.07$.

Con estos resultados, se construye la tabla 3.7 de ANOVA para el modelo completo sin interacción.

Los grados de libertad (gl) y la suma de cuadrados del modelo asociados con la tabla 3.7 se descomponen en los efectos que aparecen en la tabla 3.8.

Tabla 3.7: Análisis de varianza para los datos del ejemplo 3.7 con el modelo completo

C de V	gl	SC	CM	F	Valor p
Modelo correg.	7	13.15	1.8786	10.87	0.0002
Error	12	2.07	0.1727		
Total correg.	19	15.22			

Tabla 3.8: Suma de cuadrados tipo I para los datos del ejemplo 3.7

C de V	gl	SC	CM	F	Valor p
A	4	11.46	2.86	16.58	0.0001
B	3	1.69	0.56	3.26	0.0593
Error	12	2.07	0.17		

Con esta descomposición se caracterizan las sumas de cuadrados tipo I (Searle 1987). De los resultados de la tabla 3.8, se concluye que para la hipótesis nula

$$H_0^{(1)} : \mu_{\tau_1} = \mu_{\tau_2} = \mu_{\tau_3} = \mu_{\tau_4} = \mu_{\tau_5}$$

o, equivalentemente,

$$H_0^{(1)} : \tau_1 = \tau_2 = \tau_3 = \tau_4 = \tau_5$$

se rechaza a un nivel de significación del 5 % (valor $p = 0.0001$).

En tanto que la hipótesis nula

$$H_0^{(2)} : \mu_{\beta_1} = \mu_{\beta_2} = \mu_{\beta_3} = \mu_{\beta_4}$$

o, equivalentemente,

$$H_0^{(2)} : \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5$$

no se rechaza a un nivel de significación del 5 % (valor $p = 0.0593$).

3.5. Sumas de cuadrados y funciones estimables

En esta sección se lleva a cabo el desarrollo de cada una de las sumas de cuadrados presentadas, siguiendo la lógica del procedimiento GLM del paquete estadístico SAS (2020).

El procedimiento GLM genera la base de las funciones estimables usando cada fila no nula linealmente independiente de $(X^t X)^-(X^t X)$ para representar la forma general de las funciones estimables, involucra todos los parámetros del modelo y a cada fila no nula, linealmente independiente de $(X^t X)^-(X^t X)$, le asocia un símbolo L . El número de símbolos libres en L representa el rango máximo asociado con la matriz diseño del modelo de interés.

Según la naturaleza de los datos (balanceados y no balanceados), cada suma de cuadrados tiene características estadísticas, condiciones de uso y manejo de acuerdo con el modelo lineal planteado.

Al realizar una partición de la matriz diseño de la forma:

$$X = (X_1 : X_2 : X_3),$$

partiendo del modelo (3.1) se obtiene

$$\begin{aligned} X^t X &= \begin{pmatrix} X_1^t \\ X_2^t \\ X_3^t \end{pmatrix} (X_1 : X_2 : X_3) \\ &= \begin{pmatrix} X_1^t X_1 & X_1^t X_2 & X_1^t X_3 \\ X_2^t X_1 & X_2^t X_2 & X_2^t X_3 \\ X_3^t X_1 & X_3^t X_2 & X_3^t X_3 \end{pmatrix}. \end{aligned} \tag{3.30}$$

Con base en esta partición se generan las diferentes sumas de cuadrados, las cuales se trabajarán con más detalle en las siguientes secciones.

3.5.1. Sumas de cuadrados y funciones estimables tipo I

3.5.1.1. Sumas de cuadrados tipo I

Las sumas de cuadrados tipo I miden la reducción en la sumas de cuadrados del error cuando se adicionan nuevos parámetros al modelo. Estas sumas de cuadrados son particularmente útiles en regresión lineal múltiple, modelos polinómicos, diseños anidados, en ciertas pruebas que involucran homogeneidad de coeficientes de regresión y también suministran información acerca del efecto de la carencia de balance (multicolinealidad).

3.5.1.2. Funciones estimables tipo I

Las funciones estimables tipo I definen las hipótesis a probar cuando la reducción en suma de cuadrados es calculada para cada efecto ajustado por los efectos precedentes (Melo, Lozano y López 1999).

Las funciones estimables tipo I son obtenidas haciendo una debida partición en la matriz X , como en (3.30), de acuerdo con los parámetros del modelo. Las funciones estimables se obtienen según sea el interés de entrada de los diferentes términos al modelo. Por ejemplo, el modelo (3.1) se puede expresar como $Y = X_1\alpha + X_2\beta + X_3\gamma + e$, entonces, para obtener las funciones estimables tipo I, se construyen las siguientes matrices iniciales asociadas a cada uno de los efectos:

$$G_1 = (X_1^t X_1 : X_1^t X_2 : X_1^t X_3)$$

$$G_2 = (0 : X_2^t M_1^* X_2 : X_2^t M_1 X_3)$$

$$G_3 = (0 : 0 : X_3^t M_2^* X_3),$$

siendo $M_1^* = I - X_1(X_1^t X_1)^{-1} X_1^t$ y $M_2^* = M_1^* - M_1^* X_2^t (X_2^t M_1^* X_2)^{-1} X_2^t M_1^*$.

Con el procedimiento GLM de SAS, las funciones estimables tipo I se obtienen con la opción E_1 . Las funciones obtenidas en esta opción se encuentran a través de las siguientes matrices:

$$G_1^* = (X_1^t X_1)^{-1} G_1$$

$$G_2^* = (X_2^t M_1^* X_1)^{-1} G_2$$

$$G_3^* = (X_3^t M_2^* X_3)^{-1} G_3.$$

Las funciones estimables tipo I y sus respectivas hipótesis asociadas se encuentran colocando valores arbitrarios a los símbolos L , donde $L = (G_1^{*t} : G_2^{*t} : G_3^{*t})^t$.

Las funciones estimables tipo I y sus respectivas sumas de cuadrados dependen del orden en que los efectos son adicionados al modelo. Esta propiedad se puede verificar inmediatamente, basta tomar la matriz de diseño, la cual se obtiene cambiando las columnas correspondientes a los efectos reordenados en la matriz original.

Alguna de las funciones estimables tipo I dependen de la frecuencia de las celdas (número de observaciones). Además, para el caso de diseños desbalanceados, cada hipótesis involucra los parámetros de los efectos a probar más todos los demás parámetros del modelo propuesto.

3.5.2. Sumas de cuadrados y funciones estimables tipo II

Corresponden a la reducción en las sumas de cuadrados del error obtenida al adicionar un término después de que todos los demás han sido adicionados al modelo, excepto términos que contengan el efecto a probar.

Como la contenencia entre efectos es un concepto muy importante, se hace necesaria la siguiente definición.

Definición 3.3. Dados los efectos E_1 y E_2 , entonces E_1 está contenido en E_2 si:

- i) Ambos efectos involucran el mismo número de variables continuas. Si el número es positivo, entonces los nombres de las variables coinciden.
- ii) Si E_2 tiene más variables que E_1 y si E_1 tiene variables de tal forma que todas las de E_1 están en E_2 .

3.5.2.1. Funciones estimables tipo II

La forma general de las funciones estimables puede ser manejada para obtener pruebas de hipótesis que involucren solo el efecto en cuestión.

Goodnight (1980) describe un proceso reversible para obtener las funciones estimables tipo II basado en la siguiente definición.

Definición 3.4. Las funciones estimables tipo II, para un efecto E_1 , tienen un L de la siguiente forma.

- i) Todas las columnas de L asociadas con los efectos que no contengan a E_1 (excepto E_1) se anulan.

ii) La submatriz de L asociada con el efecto E_1 es de la forma

$$(X_1^t M^* X_1)^- (X_1^t M^* X_1), \quad (3.31)$$

siendo $M^* = I - X_0(X_0^t X_0)^- X_0^t$.

iii) Cada una de las submatrices restantes de L , asociadas con un efecto E_2 que contiene a E_1 , son de la forma

$$(X_1^t M^* X_1)^- (X_1^t M^* X_2), \quad (3.32)$$

donde X_0 son las columnas de X cuyos efectos asociados no contienen a E_1 , X_1 son las columnas de X asociadas con E_1 y X_2 son las columnas de X asociadas con el efecto E_2 , las cuales contienen a E_1 .

De la misma forma, se dan valores arbitrarios a los símbolos L correspondientes a cada fila linealmente independiente de la matriz generadora L , obteniéndose las hipótesis tipo II.

Goodnight (1980) recomienda el uso de las funciones estimables tipo II en algunos de los siguientes casos: en diseños balanceados, modelos de efectos principales, diseños puramente anidados y en algunos modelos que no involucren variables de clasificación.

3.5.3. Sumas de cuadrados y funciones estimables tipo III

El análisis tipo III está asociado con las sumas de cuadrados parciales, llamado análisis completo de mínimos cuadrados, el cual equivale al análisis de medias cuadráticas de Yates. Se aplica principalmente cuando se requiere comparar efectos principales, aun en presencia de interacción. Cada efecto es ajustado por los demás, lo que implica que si el modelo contiene solo efectos principales, entonces el análisis tipo II es igual al análisis tipo III.

3.5.3.1. Funciones estimables tipo III

En la mayoría de los diseños desbalanceados es posible planear las mismas hipótesis (funciones estimables) que se probarían en diseños balanceados. En diseños con celdas que tienen información faltante por efecto de la eliminación de las celdas sin información, estas funciones estimables se construyen como si la información fuera balanceada. Con la siguiente definición se caracterizan estas funciones.

Definición 3.5. Un conjunto de funciones estimables, una para cada efecto en el modelo, son funciones estimables tipo III si y solo si cada una de ellas constituye una hipótesis de rango máximo, es decir, la matriz L de la hipótesis $H_0 : L\theta = 0$ tiene rango igual al de la matriz X . Cada hipótesis involucra únicamente parámetros del efecto en cuestión y los parámetros de los efectos que lo contienen. Además, cada L es ortogonal a todos los L de efectos que contienen al efecto de interés.

La definición anterior implica que las funciones estimables tipo II pueden ser transformadas en las funciones estimables tipo III, haciendo que cada L de orden inferior sea ortogonal a los L de todos los efectos que contienen el efecto de interés. Adicionalmente, si un efecto no está contenido en otro, entonces las funciones estimables tipo II y tipo III coinciden. Las funciones estimables tipo III se construyen de la siguiente forma.

En primer lugar, se construye una base para el efecto E_1 con la notación de la forma general de las funciones estimables, si ningún coeficiente libre (un único símbolo) existe fuera del factor E_1 , entonces estas son las funciones estimables tipo III para E_1 .

Si existen coeficientes libres fuera del factor E_1 , entonces cada uno de estos coeficientes se iguala a una función de los coeficientes libres de E_1 , de esta manera, se construyen las funciones estimables tipo III para el efecto E_1 , ortogonales a cada una de las demás funciones estimables tipo III que contienen E_1 .

Otra alternativa para la construcción de las funciones estimables tipo III consiste en encontrar un conjunto de vectores linealmente independientes, asignando un vector a cada coeficiente libre y anulando los demás coeficientes. El número de vectores fila generado corresponde al número de coeficientes libres. Se inicia con el primer vector fila, anulando todos los parámetros asociados con E_1 . Los demás vectores se hacen ortogonales al primer vector por medio de operaciones entre filas, de tal forma que el primer factor se anule. El proceso continúa hasta anular todos los parámetros asociados con E_1 . Los parámetros resultantes son expresados nuevamente en la notación inicial y, de esta manera, se obtienen las funciones estimables tipo III asociadas a E_1 .

3.5.4. Sumas de cuadrados y funciones estimables tipo IV

Se conocen como sumas de cuadrados parciales. Originalmente fueron diseñadas para arreglos donde haya presencia de celdas vacías. En el caso que no haya celdas vacías, las sumas de cuadrados tipo III y IV coinciden.

En la construcción simplemente se considera un conjunto de datos donde no ocurran celdas vacías. Si estas existen, las sumas de cuadrados tipo IV pueden no ser únicas pues van a depender de la ubicación de los datos en las celdas.

3.5.4.1. Funciones estimables tipo IV

Para algún efecto E_1 , si E_1 no está contenida en algún otro efecto, entonces las funciones estimables tipo II, III y IV son iguales. Cuando E_1 está contenida en otros efectos, entonces las funciones estimables tipo IV asignan la misma ponderación a los niveles altos de los contrastes lineales asociados con los parámetros de E_1 .

Para un efecto E_1 las funciones estimables tipo IV pueden ser construidas con base en funciones estimables tomando los símbolos asociados con E_1 de la siguiente forma: considere que el efecto E_1 está contenido en otros efectos de acuerdo con un orden determinado (según el número de efectos que componen una interacción). Cuando hay celdas vacías, los coeficientes de efectos intermedios (de acuerdo con el orden) no tendrán siempre una asignación igual a los coeficientes asignados para los efectos de orden bajo, así, siempre se determinan primero los coeficientes de más alto orden. Una vez que los coeficientes de orden superior son hallados, los coeficientes de efectos intermedios quedan determinados.

Para la construcción de las funciones estimables tipo IV, se desarrolla el siguiente proceso para un efecto E_1 .

- i) Se selecciona un coeficiente libre de algunos de los niveles del factor E_1 y se anulan los demás coeficientes de este.
- ii) Si alguno de los niveles del factor E_1 tiene como coeficiente el cero, entonces se igualan a cero todos los coeficientes de orden superior que contengan dicho nivel.
- iii) Si un coeficiente de algún nivel superior es cero y el coeficiente del nivel asociado para E_1 es diferente de cero, entonces las funciones estimables para este efecto no son únicas.
- iv) Para cada nivel siguiente en E_1 , si el coeficiente es distinto de cero, entonces se cuenta el número de veces que aparece este en los niveles de efectos superiores y, posteriormente, se iguala cada uno de los coeficientes de este nivel dividiendo por el número de coeficientes encontrados.

Los pasos anteriores corresponden a operaciones hechas sobre el espacio vectorial generado por la base de E_1 , las cuales son equivalentes a operaciones elementales entre filas.

3.6. Hipótesis más comunes sobre filas y columnas

En el siguiente ejemplo, se ilustran de manera sencilla las diferentes sumas de cuadrados para un modelo a dos vías con interacción, caracterizando las hipótesis más comunes sobre filas y columnas en modelos superparametrizados y de medidas de celda.

A partir del ejemplo 3.1, se obtienen las diferentes hipótesis no pretendiendo presentar una generalización de los diferentes tipos de funciones estimables.

Ejemplo 3.8. *Retomando el ejemplo 3.1, la inversa de Moore Penrose de la matriz de indicadores en el modelo de medias de celda es (Iemma et al. 1999)*

$$W^+ = \begin{bmatrix} \frac{1}{2} & 0 & 0 & 0 & 0 \\ \frac{1}{2} & 0 & 0 & 0 & 0 \\ 0 & \frac{1}{1} & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{2} & 0 & 0 \\ 0 & 0 & \frac{1}{2} & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{2} & 0 \\ 0 & 0 & 0 & \frac{1}{2} & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{3} \\ 0 & 0 & 0 & 0 & \frac{1}{3} \\ 0 & 0 & 0 & 0 & \frac{1}{3} \end{bmatrix}.$$

Dentro de los varios tipos de hipótesis existentes, el procedimiento GML del SAS incorpora, en relación con el modelo en estudio, cuatro tipos de funciones y sumas de cuadrados para probar efectos de filas, cuatro para probar efectos de columnas y uno para el efecto de interacción. Aquí solamente se considera un tipo en cada caso.

- a) **Hipótesis tipo I.** Las hipótesis tipo I, igualdad entre los efectos de filas, se verifica a través de las medias ponderadas. Utilizando el modelo (3.4), se tiene

$$H_0^{(1)} : \frac{2\mu_{11} + \mu_{12} + 2\mu_{13}}{5} = \frac{2\mu_{21} + 3\mu_{22}}{5}.$$

Para el modelo (3.1), notando que $\mu_{ij} = \mu + \alpha_i + \beta_j + \gamma_{ij}$, se tiene

$$H_0^{(1)} : \alpha_1 - \alpha_2 - \frac{2}{5}\beta_2 + \frac{2}{5}\beta_3 + \frac{2}{5}\gamma_{11} + \frac{1}{5}\gamma_{12} + \frac{2}{5}\gamma_{13} - \frac{2}{5}\gamma_{21} - \frac{3}{5}\gamma_{22} = 0,$$

que sin duda no es una hipótesis simple de ser interpretada y es bien diferente de la hipótesis $H_0 : \alpha_1 = \alpha_2$ (o $H_0 : \alpha_1 - \alpha_2 = 0$), que en general, un investigador cree estar probando.

Utilizando el modelo (3.4), la hipótesis nula se puede escribir de la forma: $H_0^{(1)} : \lambda_1^t \mu = 0$, donde $\lambda_1^t = \left[\frac{2}{5}, \frac{1}{5}, \frac{2}{5}, -\frac{2}{5}, -\frac{3}{5}\right]$. En este caso, $a_1 = W^+ \lambda_1$, entonces $E(a_1^t Y) = \lambda_1^t \mu$, donde

$$a_1^t = \left[\frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}, -\frac{1}{5}, -\frac{1}{5}, -\frac{1}{5}, -\frac{1}{5}, -\frac{1}{5}\right].$$

De manera simple, se obtiene $P_1 = a_1(a_1^t a_1)^{-1} a_1^t$,

$$\therefore P_1 = \frac{1}{10} \begin{bmatrix} J_5 & -J_5 \\ -J_5 & J_5 \end{bmatrix},$$

donde J_5 es una matriz de unos de tamaño 5×5 .

Por lo tanto, se encuentra que

$$\begin{aligned} SCH_0^{(1)} &= R(\mu_i / \mu) = Y^t P_1 Y \\ &= (\lambda_1^t \hat{\mu})^t [\lambda_1^t (W^t W)^{-1} \lambda_1]^{-1} (\lambda_1^t \hat{\mu}) = 90. \end{aligned}$$

En el modelo superparametrizado, se tiene

$$SCH_0^{(1)} = R(\alpha / \mu) = Y^t P_1 Y = 90.$$

- b) **Hipótesis tipo II.** Con las hipótesis tipo II, se prueban los efectos de columnas a través de medias ponderadas de columnas ajustadas por filas. Para los datos utilizados, se tiene, conforme a Searle (1987) y Iemma et al. (1999),

$$H_0^{(6)} : \begin{cases} \frac{2\mu_{11} + 2\mu_{21}}{4} = \frac{2\bar{F}_1 + 2\bar{F}_2}{4} \\ \frac{\mu_{12} + 3\mu_{22}}{4} = \frac{\bar{F}_1 + 3\bar{F}_2}{4}, \end{cases}$$

donde

$$\bar{F}_1 = \frac{2\mu_{11} + \mu_{12} + 2\mu_{13}}{5} \quad \text{y} \quad \bar{F}_2 = \frac{2\mu_{21} + 3\mu_{22}}{5}.$$

Obteniéndose, finalmente,

$$H_0^{(6)} \begin{cases} \frac{3}{10}\mu_{11} - \frac{1}{10}\mu_{12} - \frac{1}{5}\mu_{13} + \frac{3}{10}\mu_{21} - \frac{3}{10}\mu_{22} = 0 \\ -\frac{1}{10}\mu_{11} + \frac{1}{5}\mu_{12} - \frac{1}{10}\mu_{13} - \frac{3}{10}\mu_{21} + \frac{3}{10}\mu_{22} = 0 \end{cases}$$

y, en términos del modelo (3.1),

$$H_0^{(6)} \begin{cases} \beta_1 - \beta_3 + \frac{11}{14}\gamma_{11} + \frac{3}{14}\gamma_{12} - \gamma_{13} + \frac{3}{14}\gamma_{21} - \frac{3}{14}\gamma_{22} = 0 \\ \beta_2 - \beta_3 + \frac{3}{7}\gamma_{11} + \frac{4}{7}\gamma_{12} - \gamma_{13} - \frac{3}{7}\gamma_{21} + \frac{3}{7}\gamma_{22} = 0, \end{cases}$$

la cual no contiene los efectos de fila, pues en esta hipótesis los efectos de columnas están ajustados por filas.

En el modelo (3.4), la hipótesis a probar se puede escribir como $H_0^{(6)} : \lambda_2^t \mu = \mathbf{0}$, donde

$$\lambda_2^t = \begin{bmatrix} \frac{3}{10} & -\frac{1}{10} & -\frac{1}{5} & \frac{3}{10} & -\frac{3}{10} \\ -\frac{1}{10} & \frac{1}{5} & -\frac{1}{10} & -\frac{3}{10} & \frac{3}{10} \end{bmatrix}$$

y, para la obtener la suma de cuadrados asociada a la hipótesis, se construye a_2^t como

$$a_2^t = \lambda_2^t (W^+)^t = \begin{bmatrix} \frac{3}{20} & \frac{3}{20} & -\frac{1}{10} & -\frac{1}{10} & -\frac{1}{10} & \frac{3}{20} & \frac{3}{20} & -\frac{1}{10} & -\frac{1}{10} & -\frac{1}{10} \\ -\frac{1}{20} & -\frac{1}{20} & \frac{1}{5} & -\frac{1}{20} & -\frac{1}{20} & -\frac{3}{20} & -\frac{3}{20} & \frac{1}{10} & \frac{1}{10} & \frac{1}{10} \end{bmatrix}.$$

De forma directa se tiene $P_2 = a_2(a_2^t a_2)^{-1} a_2^t$, entonces

$$P_2 = \frac{1}{140} \begin{bmatrix} 27 & 27 & 2 & -28 & -28 & 15 & 15 & -10 & -10 & -10 \\ 27 & 27 & 2 & -28 & -28 & 15 & 15 & -10 & -10 & -10 \\ 2 & 2 & 52 & -28 & -28 & -30 & -30 & 20 & -10 & -10 \\ -28 & -28 & -28 & 42 & 42 & 0 & 0 & 0 & 0 & 0 \\ -28 & -28 & -28 & 42 & 42 & 0 & 0 & 0 & 0 & 0 \\ 15 & 15 & -30 & 0 & 0 & 27 & 27 & -18 & -18 & -18 \\ 15 & 15 & -30 & 0 & 0 & 27 & 27 & -18 & -18 & -18 \\ -10 & -10 & 20 & 0 & 0 & -18 & -18 & 12 & 12 & 12 \\ -10 & -10 & 20 & 0 & 0 & -18 & -18 & 12 & 12 & 12 \\ -10 & -10 & 20 & 0 & 0 & -18 & -18 & 12 & 12 & 12 \end{bmatrix}.$$

Luego $SCH_0^{(6)} = R(\mu_{i,j}/\mu_i) = R(\beta/\mu, \alpha) = Y^t P_2 Y = 107.14$.

- c) **Hipótesis tipo III.** Con esta hipótesis, la igualdad entre efectos de fila es verificada a través de sus medias no ponderadas. En este caso, las frecuencias de celdas no son importantes. Continuando con el ejemplo de interés se tiene

$$H_0^{(3)} : \frac{\mu_{11} + \mu_{12}}{2} = \frac{\mu_{21} + \mu_{22}}{2}.$$

Se observa que para esta hipótesis no se utiliza la información de la celda (1,3). En términos del modelo (3.1), la hipótesis de interés es

$$H_0^{(3)} : \alpha_1 - \alpha_2 + \frac{1}{2}\gamma_{11} + \frac{1}{2}\gamma_{12} - \frac{1}{2}\gamma_{21} - \frac{1}{2}\gamma_{22} = 0.$$

En el modelo (3.4), la hipótesis nula se puede expresar como $H_0^{(3)} : \lambda_3^t \mu = \mathbf{0}$, donde $\lambda_3^t = [\frac{1}{2}, \frac{1}{2}, 0, -\frac{1}{2}, -\frac{1}{2}]$, realizando las respectivas operaciones, se encuentra

$$P_3 = \frac{1}{84} \begin{bmatrix} a_3^t = \left[\frac{1}{4}, \frac{1}{4}, \frac{1}{2}, 0, 0, -\frac{1}{4}, -\frac{1}{4}, -\frac{1}{6}, -\frac{1}{6}, -\frac{1}{6} \right] \\ \begin{array}{ccccccccc} 9 & 9 & 18 & 0 & 0 & -9 & -9 & -6 & -6 & -6 \\ 9 & 9 & 18 & 0 & 0 & -9 & -9 & -6 & -6 & -6 \\ 18 & 18 & 36 & 0 & 0 & -18 & -18 & -12 & -12 & -12 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -9 & -9 & 18 & 0 & 0 & 9 & 9 & 6 & 6 & 6 \\ -9 & -9 & 18 & 0 & 0 & 9 & 9 & 6 & 6 & 6 \\ -6 & -6 & 12 & 0 & 0 & 6 & 6 & 4 & 4 & 4 \\ -6 & -6 & 12 & 0 & 0 & 6 & 6 & 4 & 4 & 4 \\ -6 & -6 & 12 & 0 & 0 & 6 & 6 & 4 & 4 & 4 \end{array} \end{bmatrix}$$

y, entonces,

$$SCH_0^{(3)} = R(\mu_{ij}/\mu_{j,ij}) = R(\alpha/\mu, \beta, \gamma) = Y^t P_3 Y = 15.43.$$

- d) **Hipótesis tipo IV.** Con las hipótesis tipo IV, la igualdad entre factores de columnas se verifica a través de medias no ponderadas. En este contexto, estas pueden ser semejantes a las tipo III. Si existen celdas vacías y más de dos niveles de cada factor, en general, las hipótesis tipo III y IV son diferentes. Las hipótesis tipo IV no son únicas, en general, cuando hay celdas vacías, estas dependen de la cantidad y posición de las celdas. Las hipótesis tipo IV pueden ser obtenidas construyendo contrastes entre medias de celdas que están en la misma columna, después de cambiar las filas por columnas en la tabla 3.1, iniciándose el proceso siempre por la última fila. De esta forma, se obtiene la tabla 3.9.

Tabla 3.9: Arreglo de la información del tabla 3.1 para construir de las funciones estimables tipo IV

	i=1			i=2			
j=1	$Y_{111} = 7$	$Y_{112} = 9$	μ_{11}	$Y_{211} = 5$	$Y_{212} = 7$	—	μ_{21}
j=2	$Y_{121} = 8$	—	μ_{12}	$Y_{221} = 14$	$Y_{222} = 15$	$Y_{223} = 19$	μ_{22}
j=3	$Y_{131} = 2$	$Y_{132} = 4$	μ_{13}	—	—	—	

Entonces, la hipótesis de interés es

$$H_0^{(8)} : \begin{cases} \mu_{11} = \mu_{13} \\ \mu_{12} = \mu_{13}. \end{cases}$$

Se puede observar, en este caso, que esta hipótesis no considera ninguna observación de la fila 2. En términos del modelo (3.1), esta hipótesis se puede escribir como

$$H_0^{(8)} : \begin{cases} \beta_1 - \beta_3 + \gamma_{11} - \gamma_{13} = 0 \\ \beta_2 - \beta_3 + \gamma_{12} - \gamma_{13} = 0. \end{cases}$$

En el modelo de medias de celdas se quiere probar

$$H_0^{(8)} : \lambda_4^t \mu = \mathbf{0},$$

donde

$$\lambda_4^t = \begin{bmatrix} 0 & -1 & 1 & 0 & 0 \\ -1 & 0 & 1 & 0 & 0 \end{bmatrix}$$

y, entonces,

$$a_4^t = \begin{bmatrix} 0 & 0 & -1 & \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 & 0 & 0 \\ -\frac{1}{2} & -\frac{1}{2} & 0 & \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

y, así,

$$P_4 = \frac{1}{10} \begin{bmatrix} 3 & 3 & -2 & -2 & -2 & 0 & 0 & 0 & 0 & 0 \\ 3 & 3 & -2 & -2 & -2 & 0 & 0 & 0 & 0 & 0 \\ -2 & -2 & 8 & -2 & -2 & 0 & 0 & 0 & 0 & 0 \\ -2 & -2 & -2 & 3 & 3 & 0 & 0 & 0 & 0 & 0 \\ -2 & -2 & -2 & 3 & 3 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

encontrándose $SCH_0^{(8)} = Y^t P_4 Y = 30$.

- e) **Hipótesis sobre la interacción.** Si hay celdas vacías, se debe tomar para el modelo de interés $1/4ab(a-1)(b-1)$ posibles interacciones, de las cuales $(a-1)(b-1)$ son linealmente independientes. En presencia de celdas vacías, esa regla deja de ser válida. En el ejemplo se tiene apenas una interacción que puede ser estimada

$$\Delta = \mu_{11} + \mu_{22} - \mu_{12} - \mu_{21},$$

y no $(a-1)(b-1) = (1)(2) = 2$ interacciones estimables en el caso de no haber celdas vacías. En este contexto, la única hipótesis que puede probarse es $H_0^{(9)} : \mu_{11} + \mu_{22} - \mu_{12} - \mu_{21} = 0$.

El no rechazar la hipótesis $H_0^{(9)}$ no puede ser aceptado como un criterio válido para escoger un modelo sin interacción, puesto que no se están incluyendo todas las interacciones posibles.

En términos del modelo (3.1), la hipótesis $H_0^{(9)}$ es $H_0^{(10)} : \gamma_{11} + \gamma_{22} - \gamma_{12} - \gamma_{21} = 0$. Con los datos del ejemplo, en el modelo de medias de celdas, se obtiene

$$\lambda_5^t = [1 \ -1 \ 0 \ -1 \ 1],$$

$$a_5^t = \lambda_5^t (W^+)^t = \left[\frac{1}{2}, \frac{1}{2}, -1, 0, 0, -\frac{1}{2}, -\frac{1}{2}, \frac{1}{3}, \frac{1}{3}, \frac{1}{3} \right]$$

y

$$P_5 = \frac{1}{84} \begin{bmatrix} 9 & 9 & -18 & 0 & 0 & -9 & -9 & -6 & -6 & -6 \\ 9 & 9 & 18 & 0 & 0 & -9 & -9 & -6 & -6 & -6 \\ -18 & -18 & 36 & 0 & 0 & -18 & -18 & -12 & -12 & -12 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -9 & -9 & 18 & 0 & 0 & 9 & 9 & -4 & -4 & -4 \\ -9 & -9 & 18 & 0 & 0 & 9 & 9 & -4 & -4 & -4 \\ 6 & 6 & -12 & 0 & 0 & -4 & -4 & 4 & 4 & 4 \\ 6 & 6 & -12 & 0 & 0 & -4 & -4 & 4 & 4 & 4 \\ 6 & 6 & -12 & 0 & 0 & -4 & -4 & 4 & 4 & 4 \end{bmatrix}.$$

De esta forma, se obtiene la suma de cuadrados asociada

$$SCH_0^{(9)} = R(\mu_{ij}/\mu_{i,j}) = R(\gamma/\mu, \alpha, \beta) = Y^t P_5 Y = 42.86.$$

En la tabla 3.10, se presentan las diferentes sumas de cuadrados obtenidas con los datos del ejemplo y se destacan, en términos de la notación $R(\cdot/\cdot)$, las diferentes sumas de cuadrados obtenidas mediante el procedimiento de proyectores ortogonales.

Tabla 3.10: Resumen de las diferentes sumas de cuadrados
(a) Suma de cuadrados tipo I

C. de V.	G.L.	H_0	$R()$	SCI	CMI	F	Valor p
A (no ajustado)	1	$H_0^{(1)}$	$R(\mu_i/\mu)$	90.00	90.00	22.50	0.0051
B (ajustado)	2	$H_0^{(6)}$	$R(\mu_{ij}/\mu)$	107.14	53.57	13.39	0.0098
AB	1	$H_0^{(9)}$	$R(\mu_{i,j}/\mu_{i,j})$	42.86	42.86	10.71	0.0221

(b) Suma de cuadrados tipo II

C. de V.	G.L.	H_0	$R()$	SCII	CMII	F	Valor p
A (ajustado)	1	$H_0^{(2)}$	$R(\mu_{i,j}/\mu_j)$	9.14	9.14	2.29	0.1910
B (ajustado)	2	$H_0^{(6)}$	$R(\mu_{i,j}/\mu_i)$	107.14	53.57	13.39	0.0098
AB	1	$H_0^{(9)}$	$R(\mu_{ij}/\mu_{i,j})$	42.86	42.86	10.71	0.0221

(c) Suma de cuadrados tipo III

C. de V.	G.L.	H_0	$R()$	SCIII	CMIII	F	Valor p
A	1	$H_0^{(3)}$	$R(\mu_{ij}/\mu_{j,ij})$	15.43	15.43	3.86	0.1067
B	2	$H_0^{(7)}$	$R(\mu_{ij}/\mu_{i,ij})$	61.05	30.53	7.63	0.0302
AB	1	$H_0^{(9)}$	$R(\mu_{ij}/\mu_{i,j})$	42.86	42.86	10.71	0.0221

(d) Suma de cuadrados tipo IV

C. de V.	G.L.	H_0	$R()$	SCIV	CMIV	F	Valor p
A	1	$H_0^{(4)}$	$SCH_0^{(4)}$	15.43	15.43	3.86	0.1067
B	2	$H_0^{(8)}$	$SCH_0^{(8)}$	30.00	15.00	3.75	0.1012
AB	1	$H_0^{(9)}$	$R(\mu_{ij}/\mu_{i,j})$	42.86	42.86	10.71	0.0221

* Estas sumas de cuadrados no son únicas.

3.7. Implementación en SAS

El programa en el paquete estadístico SAS a través del cual se obtuvieron los resultados expuestos de los conjuntos de datos para los ejemplos 3.1 y 3.11 es el siguiente:

```
/* Ejemplo 3.1 */
/*Ingreso de datos*/
DATA EJEMPLO31; /*archivo del ejemplo 3.1*/
INPUT A B R Y @@;
CARDS;
1 1 1 7 1 1 2 9 1 2 1 8 1 3 1 2 1 3 2 4
2 1 1 5 2 1 2 7 2 2 1 14 2 2 2 15 2 2 3 19
;
PROC PRINT DATA=EJEMPLO31; /*Se imprimen los datos*/
```

```

/* Análisis a través del modelo superparametrizado*/
PROC GLM DATA=EJEMPLO31; /*Invocación del procedimiento GLM*/
CLASS A B; /*Se clasifica por A y B*/

/* Obtención del análisis de varianza, funciones estimables y sumas de
cuadrados */
MODEL Y= A | B/XPX E E1 E2 E3 E4 SS1 SS2 SS3 SS4;
RUN;

/* Análisis a través del modelo de medias de celdas*/
PROC GLM DATA=EJEMPLO31;
CLASS A B;
MODEL Y= A*B/XPX;
RUN;

/* Ejemplo 3.7 */
/* Análisis mediante el uso del procedimiento IML del SAS */

DATA EJEMPLO37;
INPUT Y A1 A2 A3 A4 A5 B1 B2 B3 B4 @@;
CARDS;
3.5 1 0 0 0 0 1 0 0 0 2.6 1 0 0 0 0 0 1 0 0
2.9 1 0 0 0 0 0 0 1 0 3.6 1 0 0 0 0 0 0 0 1
2.8 0 1 0 0 0 1 0 0 0 1.9 0 1 0 0 0 0 1 0 0
2.1 0 1 0 0 0 0 0 1 0 3.4 0 1 0 0 0 0 0 0 1
3.8 0 0 1 0 0 1 0 0 0 2.9 0 0 1 0 0 0 1 0 0
3.2 0 0 1 0 0 0 0 1 0 3.2 0 0 1 0 0 0 0 0 1
4.1 0 0 0 1 0 1 0 0 0 4.9 0 0 0 1 0 0 1 0 0
4.2 0 0 0 1 0 0 0 1 0 4.3 0 0 0 1 0 0 0 0 1
2.7 0 0 0 0 1 1 0 0 0 1.6 0 0 0 0 1 0 1 0 0
1.8 0 0 0 0 1 0 0 1 0 2.5 0 0 0 0 1 0 0 0 1
;
PROC PRINT DATA=EJEMPLO37;
RUN;

PROC IML;
RESET NOPRINT;
USE EJEMPLO37;
READ ALL VAR Y INTO Y;
READ ALL VAR A1 A2 A3 A4 A5 B1 B2 B3 B4 INTO X;

/* AJUSTE SECUENCIAL */

X1=J(20,1,1);
X2=X[,1:5];
X12=X1 || X2;
X123=X1 || X ;
PRINT X1 X12 X123;

```

```
/* MATRICES DE PROYECCIÓN */
```

```
P1=X1*(INV(t(X1)*X1))*t(X1);
P12=X12*(GINV(t(X12)*X12))*t(X12);
P123=X123*(GINV(t(X123)*X123))*t(X123);
PRINT P1 P12 P123;
```

```
B1=P12-P1;
B2=P123-P12;
B3=I(20)-P123;
```

```
/* ORTOGONALIDAD ENTRE MATRICES DE PROYECCIÓN */
```

```
C1=P1*B1;
C2=P1*B2;
C3=P1*B3;
C4=B1*B2;
C5=B1*B3;
C6=B2*B3;
PRINT C1 C2 C3 C4 C5 C6;
```

```
/* IDEMPOTENCIA DE LAS MATRICES DE PROYECCIÓN */
```

```
D1=P1*P1;
D2=B1*B1;
D3=B2*B2;
D4=B3*B3;
PRINT P1 D1 B1 D2 B2 D3 B3 D4;
```

```
/* OBTENCIÓN DE LAS SUMAS DE CUADRADOS */
```

```
SCMEDIA=t(Y)*P1*Y;
SCA=t(Y)*B1*Y;
SCB=t(Y)*B2*Y;
SCMODELO=t(Y)*P123*Y;
SCMODELOCOR=t(Y)*(P123-P1)*Y;
SCE=t(Y)*B3*Y;
SCTOTAL=t(Y)*Y;
SCTOTALCOR=t(Y)*(I(20)-P1)*Y;
```

```
/* OBTENCIÓN DE LOS GRADOS DE LIBERTAD */
```

```
RANMEDIA=TRACE(P1);
RAN1=TRACE(P12);
RANMODELO=TRACE(P123);
RANE=TRACE(I(20))-TRACE(P123);
RANTOTAL=TRACE(I(20));
RANMODELOCOR=RANMODELO-RANMEDIA;
RANTOTALCOR=TRACE(I(20))-TRACE(P1);
```

```

RANA=RAN1-RANMEDIA;
RANB=RANMODELO-RAN1;

/* OBTENCIÓN DE LOS CUADRADOS MEDIOS */

CMMODELO=SCMODELO/RANMODELO;
CMMODELOCOR=SCMODELOCOR/RANMODELOCOR;
CME=SCE/RANE;
CMA=SCA/RANA;
CMB=SCB/RANB;

/* OBTENCIÓN DE LAS ESTADÍSTICAS F */

F1=CMMODELO/CME;
F2=CMMODELOCOR/CME;
FA=CMA/CME;
FB=CMB/CME;

/* TABLA DE ANÁLISIS DE VARIANZA */

/* ANÁLISIS DE VARIANZA SIN CORREGIR POR LA MEDIA */

PRINT SCMODELO SCE SCTOTAL RANMODELO RANE RANTOTAL;
PRINT CMMODELO CME F1;

/* ANÁLISIS DE VARIANZA CORREGIENDO POR LA MEDIA */

PRINT SCMODELOCOR SCE SCTOTALCOR RANMODELOCOR RANE
RANTOTALCOR;
PRINT CMMODELOCOR CME F2;

/* ANÁLISIS DE VARIANZA CORREGIENDO POR LA MEDIA PARA CADA UNO
DE LOS EFECTOS PRESENTE EN EL MODELO */

PRINT SCA SCB SCE SCTOTALCOR RANA RANB RANE RANTOTALCOR;
PRINT CMA CMB CME FA FB;
RUN;

/* ANÁLISIS MEDIANTE EL USO DEL PROCEDIMIENTO GLM DEL SAS */

DATA EJEMPLO37;
INPUT Y A B @@;
CARDS;
3.5 1 1 2.6 1 2 2.9 1 3 3.6 1 4 2.8 2 1 1.9 2 2 2.1 2 3 3.4 2 4
3.8 3 1 2.9 3 2 3.2 3 3 3.2 3 4 4.1 4 1 4.9 4 2 4.2 4 3 4.3 4 4
2.7 5 1 1.6 5 2 1.8 5 3 2.5 5 4
;
PROC PRINT DATA=EJEMPLO37;
RUN;

```



```
PROC GLM DATA=EJEMPL037;
CLASS A B;
MODEL Y= A B;
RUN;
```

3.8. Implementación en R

El programa en el software libre R a través del cual se obtuvieron los resultados expuestos en el conjunto de datos para el ejemplo 3.1 es el siguiente:

```
#####
## Ejemplo 3.1 ##
#####

# Introducción de los datos del ejemplo 3.1
ejemplo3.1 <- data.frame(A=factor(c(rep(1,5),rep(2,5))),
  B=factor(c(1,1,2,3,3,1,1,2,2,2)),
  R=factor(c(1,2,1,1,2,1,2,1,2,3)),
  Y=c(7,9,8,2,4,5,7,14,15,19))

anova <- aov(Y ~ A*B, data=ejemplo3.1)
summary(anova)
print(model.tables(anova,"means"),digits=3)

library(car)
Anova(anova, type="II")
Anova(anova, type="III", singular.ok=T)
```

3.9. Ejercicios

1. Escriba los supuestos que se hacen sobre el error experimental en los modelos y diga qué importancia tienen en el análisis estadístico.
2. Dado el modelo lineal

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 2 \\ 1 \end{pmatrix} \theta + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \end{pmatrix}$$

halle la estimación de mínimos cuadrados de θ y la suma de cuadrados del error.

3. Sean $X \sim N(\mu_1, \sigma^2)$, $Y \sim N(\mu_2, \sigma^2)$ variables independientes. En muestras de tamaño n_1 de X , n_2 de Y , plantee la hipótesis nula $H_0: \mu_1 = \mu_2$ mediante el concepto de hipótesis lineal contrastable y

deduzca el test t de Student de comparación de medias a partir del test F .

4. Para el modelo particionado $E(\mathbf{Y}) = \mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{X}_2\boldsymbol{\beta}_2$, considere el modelo superparametrizado $E(y_{ij}) = \mu + \alpha_i$, con $i = 1, \dots, a$ y $j = 1, \dots, n_i$.
 - a. Expréselo en la forma del modelo particionado.
 - b. Con la apropiada partición del modelo, demuestre

$$R(\alpha/\mu) = \sum_{i=1}^a n_i (\bar{y}_{i.} - \bar{y}_{..})^2.$$

5. Suponga el modelo $y_{ij} = \mu + \tau_i + e_{ij}$, $i = 1, \dots, 6$, $j = 1, \dots, r$.
 - a. Deduzca las ecuaciones normales por el método de mínimos cuadrados y estime los parámetros μ y τ_i .
 - b. Encuentre la varianza asociada a los estimadores hallados en a., es decir, $Var(\hat{\mu})$ y $Var(\hat{\tau}_i)$.
 - c. Construya la base de las funciones estimables e identifique cuáles de las siguientes funciones paramétricas son estimables:
 $L_1 = 2\tau_1 - \tau_2 - \tau_3$, $L_2 = \tau_1 + \tau_2 + \tau_3 - 4\tau_4$, $L_3 = \tau_1 - \tau_5$ y $L_4 = \tau_2 - \tau_6$.
 - d. A partir de los resultados encontrados en a., encuentre los estimadores para las funciones paramétricas estimables halladas en c. y diga, además, cuáles de los contrastes son ortogonales.
 - e. Suponga que $\bar{y}_{1.} = 7$, $\bar{y}_{2.} = 9$, $\bar{y}_{3.} = 14$, $\bar{y}_{4.} = 16$, $\bar{y}_{5.} = 10$, $\bar{y}_{6.} = 20$, $CME = 26$, con $r = 4$. Lleve a cabo la prueba para los L 's del punto c que sean estimables.
6. Dado el sistema de ecuaciones lineales con incógnitas α y β :

$$\alpha + x_1\beta = y_1.$$

$$\alpha + x_2\beta = y_2.$$

$$\alpha + x_3\beta = y_3.$$

$$\alpha + x_4\beta = y_4.$$

- a. Escriba en forma matricial $\mathbf{X}\boldsymbol{\theta} = \mathbf{Y}$, con $\boldsymbol{\theta} = (\alpha, \beta)^t$.
- b. Verifique que la matriz $\mathbf{X}$ tiene rango columna completo.

c. Verifique que para $i = 1, 2, 3, 4, \dots, n$

$$\text{i. } \mathbf{X}^t \mathbf{X} = \begin{bmatrix} n & \sum_i x_i \\ \sum_i x_i & \sum_i x_i^2 \end{bmatrix}, \quad \text{ii. } \mathbf{X}^t \mathbf{Y} = \begin{bmatrix} \sum_i y_i \\ \sum_i x_i y_i \end{bmatrix}.$$

d. Usando c. encuentre las ecuaciones normales.

e. Pruebe que $\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}$ y que

$$\hat{\beta} = \frac{\sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n}}{\sum x_i^2 - \frac{(\sum x_i)^2}{n}},$$

$$\text{donde } \bar{x} = \frac{\sum x_i}{n}, \bar{y} = \frac{\sum y_i}{n}, \hat{\boldsymbol{\theta}} = \begin{bmatrix} \hat{\alpha} \\ \hat{\beta} \end{bmatrix}.$$

f. Considere $X = \begin{bmatrix} 10 \\ 20 \\ 30 \\ 40 \end{bmatrix}$, $Y = \begin{bmatrix} 100 \\ 90 \\ 150 \\ 160 \end{bmatrix}$ y determine:

i. $\hat{\alpha}$ y $\hat{\beta}$ a través de e.

ii. $M = \hat{\boldsymbol{\theta}}^t \mathbf{X}^t \mathbf{Y}$.

iii. $M = \mathbf{Y}^t \mathbf{P} \mathbf{Y}$, con $\mathbf{P} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t$.

iv. $E = \mathbf{Y}^t \mathbf{Y} - \hat{\boldsymbol{\theta}}^t \mathbf{X}^t \mathbf{Y}$.

7. Para el modelo $y_{ij} = \mu + \alpha_i + \beta_j + e_{ij}$, $i = 1, 2, \dots, a$, $j = 1, 2, \dots, b$.

a. Obtenga el conjunto de funciones estimables.

b. Muestre que $SC(\boldsymbol{\alpha}/\mu) = b \sum_{i=1}^a (\bar{y}_{i.} - \bar{y}_{..})^2$.

8. Considere el conjunto de datos

	t_1	t_2
b_1	2	4
b_2	3	6
b_3	5	5

y el modelo $y_{ij} = \mu + t_i + b_j + e_{ij}$, donde $i = 1, 2 = n$ índice de tratamientos, $j = 1, 2, 3 = p$ índice de bloques. Considere la siguiente igualdad

$$\mathbf{Y}^t \mathbf{A}_T \mathbf{Y} = \mathbf{Y}^t \mathbf{A}_b \mathbf{Y} + \mathbf{Y}^t \mathbf{A}_t \mathbf{Y} + \mathbf{Y}^t \mathbf{A}_R \mathbf{Y},$$

donde $\mathbf{A}_b = \frac{1}{np} [\mathbf{E}_n \otimes (p\mathbf{I}_p - \mathbf{E}_p)]$, $\mathbf{A}_t = \frac{1}{np} [(n\mathbf{I}_n - \mathbf{E}_n) \otimes \mathbf{E}_p]$, $\mathbf{A}_R = \frac{1}{np} [(n\mathbf{I}_n - \mathbf{E}_n) \otimes (p\mathbf{I}_p - \mathbf{E}_p)]$ y $\mathbf{A}_T = \mathbf{A}_b + \mathbf{A}_t + \mathbf{A}_R$. En este caso, se tienen 6 observaciones y, además, $\mathbf{I}$ y $\mathbf{E}$ son matrices identidades y matrices cuadradas con todos los elementos iguales a 1, respectivamente.

- a. Encuentre la tabla de análisis de varianza.
- b. Pruebe, con base en la información, las hipótesis pertinentes en este caso.

9. Considere el modelo

$$E(Y_{ij}) = \mu + \tau_i, \quad i = 1, 2, \dots, m, \quad j = 1, 2, \dots, n_i$$

y los contrastes

$$C_1 = \sum_{i=1}^m a_i^{(1)} \tau_i \quad \text{y} \quad C_2 = \sum_{i=1}^m a_i^{(2)} \tau_i.$$

Establezca la condición necesaria y suficiente para que C_1 y C_2 sean ortogonales.

10. Considere el modelo $(Y, X\boldsymbol{\beta}, \sigma^2\mathbf{I})$, donde

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{bmatrix},$$

$\mathbf{Y}^t = [3, 2, 9, 10, 3, 1]$, $\boldsymbol{\beta}^t = [\mu, \tau_1, \tau_2, \tau_3]$ y suponga que $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2\mathbf{I})$. En el modelo se desean probar, no simultáneamente, los siguientes juegos de hipótesis:

$$H_0^{(1)} : \tau_1 = 2 + \tau_2, \quad H_0^{(2)} : \begin{cases} \tau_1 = \frac{\tau_2 + \tau_3}{2} \\ \tau_2 = \tau_3. \end{cases}$$

- a. Muestre si estas hipótesis son posibles de probar estadísticamente.
- b. Pruebe aquella(s) hipótesis que según lo obtenido en a. son estimables.

11. Considere el modelo $E(y_{ij}) = \mu + \tau_i + \beta_j$, $i = 1, 2, \dots, 5$, $j = 1, 2, \dots, b$.

a. Obtenga estimadores para

$$\gamma_1 = -2\tau_1 - \tau_2 + \tau_4 + 2\tau_5.$$

$$\gamma_2 = 2\tau_1 - \tau_2 - 2\tau_3 - \tau_4 + 2\tau_5.$$

$$\gamma_3 = -\tau_1 + 2\tau_2 - 2\tau_4 + \tau_5.$$

$$\gamma_4 = \tau_1 - 4\tau_2 + 6\tau_3 - 4\tau_4 + \tau_5.$$

Diga si son MELIS y justifique su respuesta.

- b. Muestre que $H_0 : \gamma_1 = \gamma_2 = \gamma_3 = \gamma_4 = 0$ es equivalente a la hipótesis $H_0 : \tau_i = a + b_i$, $i = 1, 2, \dots, 5$ y explique en detalle cómo probar esta última hipótesis.
12. Suponga que se tiene el modelo (1): $Y = X\beta + e$. Sea P una matriz ortogonal tal que se tiene el modelo (2) $P^{-1}Y = P^{-1}X\beta + P^{-1}e$. Pruebe que $\lambda^t \beta$ es estimable en el modelo (1) si y solo si es estimable en el modelo (2).
13. Considere el modelo $E(y_{ij}) = \mu + \alpha_i$ con $i = 1, \dots, m$, $j = 1, \dots, k$
- a. Si $\sum a_i^{(1)} = 0$ y $\sum a_i^{(2)} = 0$, encuentre:
 $Cov[MELI(\sum a_i^{(1)} \alpha_i), MELI(\sum a_i^{(2)} \alpha_i)]$.
- b. Encuentre $SC(MELI(\sum a_i \alpha_i))$, $SC(Y_{i.}/k)$ y $SC(Y_{..}/mk)$.
14. Considere el modelo de medias de celdas $y_{ij} = \mu_i + \epsilon_{ij}$ con $i = 1, \dots, p$ y $j = 1, \dots, n_i$.
- a. Determine el test estadístico para la hipótesis $H_0 : \mu_1 = \dots = \mu_p$.
- b. Pruebe que μ_i es estimable y obtenga su MELI y su varianza.
- c. Proponga tres conjuntos de contrastes que sean ortogonales (suponga para este caso que $p = 5$) y obtenga la varianza y la covarianza de estos contrastes.
15. Suponga el modelo $y_{ij} = \mu + \alpha_i + \beta_j + e_{ij}$, con $i = 1, \dots, m$, $j = 1, \dots, k$. Obtenga las siguientes sumas de cuadrados usando sumatorias: SCT_{CM} , SCM_{CM} y SCE . Encuentre los grados de libertad y sus esperanzas al suponer que $e_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$.

16. Suponga el siguiente conjunto de datos:

T_1	T_2	T_3
2	4	6
3	2	7
2	5	8

- Determine dos soluciones de las ecuaciones normales.
 - Construya la base de funciones estimables.
 - Proponga dos funciones estimables de interés y obtenga su MELI.
 - Cómo quedaría estructurado el modelo particionado en k partes, presente esta partición en una tabla de análisis de varianza.
17. Considere un experimento completamente aleatorizado, en el cual se obtuvieron los siguientes resultados:

α_1	α_2	α_3
4	3	10
5	4	14
9	2	11

Caracterizándose el modelo $y_{ij} = \mu + \tau_i + e_{ij}$.

- Escriba el sistema en forma matricial.
- Determine
 - $\theta_1^0 = (X^t X)_1^0 X^t Y$.
 - $\theta_2^0 = (X^t X)_2^0 X^t Y$.
- Verifique cuáles, entre el siguiente conjunto de funciones paramétricas, son estimables.
 - $\lambda_1 \theta = \alpha_1 - \alpha_2$.
 - $\lambda_2 \theta = \mu$.
 - $\lambda_3 \theta = \alpha_i, \quad i = 1, 2, 3$.
 - $\lambda_4 \theta = \sum_{i=1}^3 \alpha_i$.
 - $\lambda_5 \theta = \mu + 2\alpha_1 - \alpha_2$.
 - $\lambda_6 \theta = \mu + \alpha_i, \quad i = 1, 2, 3$.
 - $\lambda_7 \theta = 2\alpha_1 - \alpha_2 - \alpha_3$.
- Para el conjunto de funciones estimables en c., determine combinaciones de las observaciones tales que $E(a^t Y) = \lambda^t \theta$.

- e. Para el conjunto de funciones estimables en c., encuentre el MELI y su varianza.
 - f. Para el conjunto de funciones estimables en c., compare $V(\lambda^t \theta^0)$ con $V(a^t Y)$ y comente.
 - g. Calcule $Y^t Y$, $Y^t P_X Y$, $Y^t (I - P_X) Y$, con $P_X = X(X^t X)^{-1} X^t$.
 - h. Verifique que $\sum_{i=1}^t (n_i - 1) S_i^2 = Y^t (I - P_X) Y$.
 - i. Obtenga $Y^t (P_X - P_1) Y$, con $P_1 = X_1 (X_1^t X_1)^{-1} X_1^t$.
 - j. Verifique que P_X y $(I - P_X)$ son simétricas, idempotentes y si hay ortogonalidad.
 - k. Determine $E \left(\frac{Y^t (P_X - P_1) Y}{\text{ran}(P_X - P_1)} \right)$ y $E \left(\frac{Y^t (I - P_X) Y}{\text{ran}(I - P_X)} \right)$.
 - l. Obtenga estimaciones puntuales y por intervalos para el conjunto de funciones estimables.
18. Para el modelo $y_i = \alpha + i\beta(x_i - \bar{x}) + \varepsilon_i$, $i = 1, \dots, n$, donde $\varepsilon_i \stackrel{iid}{\sim} N(0, \sigma^2)$, encuentre los estimadores mínimos cuadrados de α y de β . Obtenga un estimador de σ^2 .
19. Considere el siguiente conjunto de datos:

	β_1	β_2	β_3
α_1	4	6	8
		9	6
			5
α_2	5	4	3
	7		

Si los datos están caracterizados por el modelo $y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$.

- a. Construya la base de las funciones estimables.
 - b. Muestre en forma explícita las ecuaciones normales.
 - c. Calcule $R(\mu, \alpha)$, $R(\mu, \beta)$, $R(\mu, \alpha, \beta)$ y $R(\mu, \alpha, \beta, \alpha\beta)$, en todos los casos caracterice muy bien la matriz de proyección.
20. Para el modelo $y_{ij} = \mu + \alpha_i + \beta_j + \varepsilon_{ij}$, $i = 1, 2, \dots, k$, $j = 1, 2, \dots, r$. Si, además, $Y \sim N(X\theta, \sigma^2 I)$, encuentre la prueba de máxima verosimilitud para las hipótesis:

a. $H_0 : \alpha_1 = \alpha_2 = \cdots = \alpha_k.$

b. $H_0 : \beta_1 = \beta_2 = \cdots = \beta_r.$

21. Suponga un modelo de dos vías de clasificación con dos filas y dos columnas, pruebe que:

a. $R(\alpha/\mu) = \frac{n_{1.}n_{2.}(\bar{y}_{1..}-\bar{y}_{2..})^2}{n_{..}}.$

b. $R(\beta/\mu, \alpha) = \frac{(\bar{y}_{.1.}-n_{11}\bar{y}_{1.}, -n_{21}\bar{y}_{2..})^2}{\frac{n_{11}n_{12}}{n_{1.}} + \frac{n_{21}n_{22}}{n_{2.}}}.$

c. $R(\gamma/\mu, \alpha, \beta) = \frac{(\bar{y}_{11.}-\bar{y}_{12.}-\bar{y}_{21.}+\bar{y}_{22.})^2}{\sum \frac{1}{n_{ij}}}.$

Capítulo
cuatro

**Clasificación de
modelos en el
análisis de
varianza y
diagramas de
estructura**

Los métodos tradicionales de análisis de varianza (ANOVA) desarrollan cálculos a partir de los subíndices de los términos que aparecen en el modelo estadístico asociado con el experimento en consideración. En este capítulo, se presenta una estrategia gráfica para obtener resultados “aproximadamente” similares a los que se consiguen con los métodos algebraicos corrientes del análisis de varianza. La representación visual provee una herramienta más clara para identificar cómo obtener los grados de libertad, las sumas de cuadrados, los cuadrados medios y las estadísticas F a partir de las relaciones existentes entre los factores experimentales.

4.1. Clasificación de los modelos en el análisis de varianza

En esta sección, se hace una síntesis del artículo de Eisenhart (1947) en el cual muestra las diferencias entre modelos de efectos fijos y modelos de efectos aleatorios dentro del contexto del análisis de varianza. Se considera que el análisis de varianza es usado para proveer soluciones a dos clases amplias de problemas.

Clase I: detección y estimación de relaciones entre las medias de subconjuntos de objetos del universo considerado. En esta clase se hace inferencia sobre la diferencia de los efectos medios de tratamientos, así como el análisis de regresión y los análisis armónicos. Las pruebas de significación en conexión con estos problemas, que en la mayoría de los casos se hace mediante la prueba t , son extensiones de la teoría de pequeñas muestras, desarrollada por Willian Gosset (Student).

Clase II: detección y estimación de componentes de variación (aleatorias), asociados con una población compuesta. En esta clase se incluye todo el problema de inferencia en los componentes de varianza, los cuales son atribuibles a la variación aleatoria de las características de los individuos de un tipo genérico particular con respecto a los valores medios de estas características en la población.

De otra forma, se consideran los tratamientos como una muestra aleatoria de una población de tratamientos; a diferencia del caso anterior, la inferencia se hace sobre las varianzas poblacionales de tales tratamientos.

Es importante observar que en los problemas de Clase I los correspondientes parámetros son medias y los resultados de interés se hallan interrelacionados con la comparación entre dos o más efectos medios (contrastes), así como su dependencia funcional con respecto a un conjunto de variables

independientes (polinomios ortogonales, análisis de regresión, métodos de aplicación en superficies de respuesta).

En la Clase II, los parámetros correspondientes son varianzas y sus magnitudes absolutas y relativas son de gran importancia, así como la estimación de los índices de selección y heredabilidad en problemas genómicos y en muchos otros caso de la investigación científica.

4.1.1. Supuestos fundamentales

Con base en los resultados obtenidos por Eisenhart (1947) y con la finalidad de hacer inferencia en la Clase I, si $y_{ijk\dots m}$ representa la respuesta de interés, los siguientes supuestos son necesarios:

- i) Los $y_{ijk\dots m}$ son variables aleatorias que se distribuyen alrededor de los verdaderos valores medios $\mu_{ijk\dots m}$ ($i = 1, \dots, I, j = 1, \dots, J, k = 1, \dots, K, \dots, m = 1, \dots, M$), donde $\mu_{ijk\dots m}$ son valores constantes.
- ii) Los parámetros $\mu_{ijk\dots m}$ se encuentran relacionados en forma lineal, así, por ejemplo, cuando se hace uso del modelo a dos vías de clasificación se encuentra que

$$\mu_{ij} = \mu_{..} + (\mu_{i.} - \mu_{..}) + (\mu_{.j} - \mu_{..}) + (\mu_{ij} - \mu_{i.} - \mu_{.j} + \mu_{..}).$$

- iii) Las variables aleatorias $y_{ijk\dots m}$ son homocedásticas y mutuamente incorrelacionadas, es decir, $Var(Y) = \sigma^2 I$. Para el caso de un modelo a dos vías de clasificación, se tiene

$$Var(y_{ij}) = \sigma^2 \text{ y } Cov(y_{ij}, y_{i'j'}) = 0, \text{ para todo } i \neq i', j \neq j'.$$

- iv) Los $y_{ijk\dots m} \stackrel{iid}{\sim} N(\mu_{ijk\dots m}, \sigma^2)$.

Cuando se satisface (iv), el supuesto (i) resulta redundante. Con los supuestos anteriores, todos los procedimientos del análisis de varianza para estimar y juzgar la existencia de relaciones lineales fijas (contrastes) son válidos.

Para la Clase II, en el cual los parámetros son componentes de varianza, se tienen los siguientes supuestos:

1. Los $y_{ijk\dots m}$ son variables aleatorias que se distribuyen alrededor de un valor medio $\mu_{\dots\dots}$ (valor fijo).

2. Las variables aleatorias $y_{ijk\dots m}$ son sumas de componentes, así, en el caso de dos vías de clasificación

$$y_{ij} = \mu_{..} + (\mu_{i.} - \mu_{..}) + (\mu_{.j} - \mu_{..}) + (\mu_{ij} - \mu_{i.} - \mu_{.j} + \mu_{..}) + \epsilon_{ij},$$

estas componentes lineales son aleatorias.

3. En el caso de un modelo a dos vías de clasificación, las variables aleatorias $(\mu_{i.} - \mu_{..})$, $(\mu_{.j} - \mu_{..})$ y ϵ_{ij} se distribuyen con varianza σ_r^2 ; σ_c^2 y σ^2 respectivamente. Luego la covarianza entre estos componentes es nula.
4. Los desvíos en un modelo a dos vías de clasificación son $(\mu_{i.} - \mu_{..})$, $(\mu_{.j} - \mu_{..})$ y ϵ_{ij} se distribuyen en forma normal.

Cuando los supuestos anteriores se satisfacen, las inferencias sobre los componentes de varianza son válidas.

El uso del Modelo I o II depende de la forma cómo fue planeado el experimento, de cómo fueron obtenidas las observaciones y de los siguientes lineamientos:

- a) Si las conclusiones se van a restringir a los objetos realmente estudiados (tratamientos y unidades experimentales), a las fuentes inmediatas que contienen estos objetos o, extensiones de poblaciones más generales.
- b) Con repeticiones completas del experimento se estudiarán de nuevo los mismos objetos, nuevas muestras de fuentes idénticas, nuevas ordenaciones experimentales o se extraerán nuevas muestras de poblaciones más generales (selección aleatoria de tratamientos).

4.2. Diagramas de estructuras y análisis de varianza en diseños experimentales

El uso de diagramas de estructura es de gran utilidad práctica en la construcción de modelos para el análisis de varianza con datos balanceados, ya que de ellos se obtiene fácilmente la estructura de la tabla de ANOVA (grados de libertad, suma de cuadrados y esperanza de cuadrados medios). Del conocimiento de los cuadrados medios esperados, se plantean las hipótesis de interés.

En este tipo de estudios, se tiene un conjunto de observaciones que pueden clasificarse teniendo en cuenta uno o más factores de clasificación.

Estos factores agrupan a los individuos de clases disjuntos y generalmente se denotan por las letras mayúsculas ($A, B, C, \dots$) o ($A_1, A_2, A_3, \dots$). Cada factor, por lo general, se evalúa a través de diferentes niveles ($a_0, \dots, a_{n_a}; b_0, \dots, b_{n_b}; \dots$).

Cada subclase la constituyen las combinaciones de los diferentes niveles de los factores ($a_0b_0\dots, a_0b_1\dots, \dots$), y estos, a su vez, identifican los tratamientos. Cuando el número de observaciones que se hace sobre un determinado factor es el mismo, se dice que hay una estructura balanceada de datos, por ejemplo, cuando se tienen tres factores A, B y C , se dice que hay balanceamiento respecto a ABC si el número de observaciones asociado con las diferentes combinaciones de niveles de los factores son las mismas.

En el desarrollo usual de análisis de varianza, los cálculos se basan en los términos que aparecen en el modelo lineal. Por ejemplo, en un modelo a una vía de clasificación $y_{ij} = \mu + \alpha_i + \epsilon_{ij}$, $i = 1, \dots, a$, $j = 1, \dots, n$, se busca examinar el efecto de α_i y el de ϵ_{ij} .

Los diagramas de estructura en su forma más general son una aproximación gráfica y simbólica al ANOVA. En la aproximación simbólica, un diagrama de estructura sirve como objeto de referencia tanto para la derivación de pruebas estadísticas como para los cálculos implicados en estas según Taylor y Hilton (1981). La representación visual ayuda al análisis, por cuanto exhibe la relación entre los factores experimentales, lo cual sugiere cómo deben ser los cálculos en el ANOVA, particularmente los grados de libertad y sumas de cuadrados. Los diagramas son fotografías que muestran si los factores son fijos o aleatorios, el número de niveles para cada factor y la relación entre estos (efectos cruzados y/o efectos anidados o jerárquicos).

4.2.1. Diagramas de estructuras

Una representación de un diseño experimental, debe conllevar a una simplificación del mismo, los diagramas de estructura cumplen este papel con los diseños balanceados completos.

En diseño experimental se dice que un factor B está *anidado* dentro de otro factor A si cada nivel de B aparece con un único nivel de A . En un diseño anidado balanceado se tiene una relación uno a uno entre los niveles del factor B con los de A . Los factores A y B están completamente *cruzados* si cada nivel de A aparece con cada nivel de B . De otra forma, los factores cruzados en un diseño balanceado corresponden al producto cartesiano entre los niveles de los respectivos factores.

Para representar un diseño experimental, los factores se notan con letras mayúsculas, las letras subrayadas indican que se trata de factores aleatorios. El

anidamiento es indicado por líneas de conexión descendente; un factor está anidado en el (los) factor(es) que lo conectan superiormente. El cruzamiento se observa entre factores que no estén conectados entre sí.

Como visión general, se presentan los siguientes esquemas particulares (figura 4.1), los cuales pueden estudiarse con mayor detalle en Méndez (1981). En estos diseños μ representa la media experimental, A , B y C son los factores y ϵ el error experimental.




Figura 4.1: Diagramas de estructura particulares.

De la figura 4.1 (a), se puede decir que identifica un diseño a una vía de clasificación. Nótese que μ anida tanto al factor A como al error ϵ , mientras el factor A anida a ϵ .

La figura 4.1 (b) caracteriza un diseño de doble vía de clasificación con los factores A y B cruzados, este se conoce como un diseño bifactorial con interacción. También puede corresponder a un diseño de bloques aleatorios completos, aunque el gráfico indica la presencia de cruce entre A y B . En este caso, no estarían conectados. Debe tenerse presente que en este tipo de diseños B no es un factor como tal, sino que obedece a un control local “decidido” por el investigador (para proteger el efecto de A de agentes extraños).

Para el caso de la figura 4.1 (c), el factor aleatorio C está anidado en el factor B , y este, a su vez, está anidado en el factor A , no hay factores cruzados. Un ejemplo tomado de Montgomery (1984) ilustra apropiadamente el diagrama anterior: se quiere investigar la dureza de dos formulaciones diferentes de una aleación metálica (factor A), tres horneadas de cada formulación fueron preparadas (factor B) y dos lingotes son escogidos aleatoriamente (factor aleatorio C), a estos se les midió dos veces su dureza; este diagrama caracteriza un arreglo de efectos mixtos en una estructura anidada.

El diseño descrito en la figura 4.1 (d) representa un modelo a tres vías de clasificación en el que los factores B y C están cruzados entre sí y cada uno anidado en el factor A .

Los diagramas de estructura no solo dan a entender la relación entre los factores experimentales, sino que sugieren el correspondiente modelo estadístico. La regla es simple: cada factor es escrito aditivamente como un efecto más los términos de interacción, cada uno de los cuales es el producto de los factores que se cruzan. Los efectos anidados se describen de acuerdo con su cruce con otros factores (puede darse anidamiento y cruce a la vez). En este caso se coloca dentro de un paréntesis el subíndice de cada efecto principal.

Los modelos asociados con los diagramas de la figura 4.1 son:

- (a) $y_{ij} = \mu + A_i + \epsilon_{j(i)}, \quad i = 1, \dots, I, \quad j = 1, \dots, J$
- (b) $y_{ijk} = \mu + A_i + B_j + (AB)_{ij} + \epsilon_{k(ij)}, \quad i = 1, \dots, I, \quad j = 1, \dots, J, \quad k = 1, \dots, K$ o también $y_{ijk} = \mu + A_i + B_j + \epsilon_{k(ij)}$, para el caso de un diseño de bloques o un modelo de efectos cruzados sin interacción cuando no aparece la línea punteada.
- (c) $y_{ijkl} = \mu + A_i + B_{j(i)} + C_{k(ij)} + \epsilon_{l(ijk)}, \quad i = 1, \dots, I, \quad j = 1, \dots, J, \quad k = 1, \dots, K, \quad l = 1, \dots, L$
- (d) $y_{ijkl} = \mu + A_i + B_{j(i)} + C_{k(i)} + (BC)_{jk(i)} + \epsilon_{l(ijk)}, \quad i = 1, \dots, I, \quad j = 1, \dots, J, \quad k = 1, \dots, K, \quad l = 1, \dots, L.$

Taylor y Hilton (1981) presentan los siguientes conceptos acerca de los factores y las interacciones:

- i *Conjunto de factores*: el conjunto de todos los factores en un diseño experimental se llama *conjunto diseño*. Cada efecto, en cualquier conjunto de diseño puede ser particionado en grupos más pequeños y es llamado *conjunto de factores*. El principio básico que caracteriza el conjunto de factores es que cualquier efecto únicamente particiona el conjunto diseño en conjuntos con características disjuntas, necesarias para los cálculos del análisis de varianza.

Scheffé (1959) emplea la terminología de factor *vivo*, *inerte* y *ausente* para ayudar a identificar algunos cálculos en el análisis estadístico. Los factores que aparecen en el nombre del correspondiente efecto para los subíndices sin paréntesis son llamados factores *vivos*. Los factores que anidan otros factores, es decir, los que señalan los subíndices dentro de los paréntesis, son denominados factores *inertes*. Los factores restantes,

los cuales no aparecen nombrados como un factor ni anidan factor alguno, se llaman *ausentes*. Esta clasificación particiona el conjunto diseño en tres conjuntos disjuntos de factores (vivos, inertes y ausentes). Otra manera de reconocer los factores es a partir de la consideración de fijos o aleatorios, los cuales determinan los tipos de modelos, la estimación de los parámetros y las pruebas de hipótesis a desarrollar.

- ii *Interacción*: sean $Q_1, \dots, Q_n$ efectos. La interacción entre los efectos se notará por $[Q_1, \dots, Q_n]$ para indicar la agrupación de los factores $Q_1, \dots, Q_n$, excepto para los factores duplicados y los que anidan algunos de estos.

4.2.2. Derivación de fórmulas

La derivación de fórmulas para el ANOVA usualmente es apoyada por el análisis de los términos presentes en el modelo (efectos vivos, inertes o ausentes). Estas reglas de análisis pueden ser adoptadas para los mismos propósitos con diagramas de estructura, teniendo en cuenta los conceptos acerca de conjuntos de factores e interacción explicados anteriormente. En Taylor y Hilton (1981) se enuncian algunas reglas útiles para el análisis de varianza; se insiste en la validez de las reglas para diseños balanceados y completos.

Regla 1. Efectos Admisibles

Un efecto admisible es toda combinación de letras de factores en el cual ningún factor en una combinación está conectado con otro factor de la combinación por líneas ascendentes. Se sugiere escribir los efectos de acuerdo con el orden de la interacción, empezando por la media y todos los efectos principales, luego con todos los efectos dobles, enseguida los triples, y así sucesivamente hasta escribir todos los términos involucrados en el modelo.

La figura 4.2 permite describir un experimento en el cual se tienen n_v variedades ensayadas en n_l localidades donde se seleccionaron n_f campos de cultivo de los cuales se estudiaron n_p plantas con n_e repeticiones.

De la figura 4.2, se obtiene:

$$\begin{aligned} V &: \mu \\ L &: \mu \\ VL &: \mu \\ F &: L\mu \\ \underline{FL} &: L\mu \end{aligned}$$

$$\begin{array}{l}
FV : L\mu \\
VFL : L\mu \\
\hline
P : VFL\mu \\
PV : V\mu \\
\hline
\epsilon : PFLV\mu.
\end{array}$$




Figura 4.2: Diagrama de estructura para determinar efectos admisibles.

Las interacciones subrayadas no tienen sentido, esto es, “no existen”, pues no van a ser efectos admisibles. Una forma práctica para determinar si una interacción “no existe” es que alguna letra del lado izquierdo esté contenida en el lado derecho.

Entonces, el modelo lineal asociado con la figura 4.2 es:

$$Y_{ijkmr} = \mu + V_i + L_j + (VL)_{ij} + F_{k(j)} + (VF)_{ik(j)} + P_{m(ijk)} + \epsilon_{r(ijkm)}, \quad (4.1)$$

donde $i = 1, \dots, n_v$ (número de variedades), $j = 1, \dots, n_l$ (número de localidades), $k = 1, \dots, n_f$ (número de campos de cultivo), $m = 1, \dots, n_p$ (número de plantas) y $r = 1, \dots, n_\epsilon$ (número de repeticiones).

Con la finalidad de hacer estimables todas las funciones sobre efectos fijos involucradas en el modelo (4.1), a este se le imponen las siguientes restricciones:

$$\begin{aligned}
\sum_{i=1}^{n_v} V_i &= \sum_{j=1}^{n_l} L_j = 0 \\
\sum_{i=1}^{n_v} (VL)_{ij} &= \sum_{j=1}^{n_l} (VL)_{ij} = \sum_{i=1}^{n_v} (VF)_{ik(j)} = \sum_{k=1}^{n_f} (VF)_{ik(j)} = 0.
\end{aligned}$$

Adicionalmente, se supone que

$$F_{k(j)} \stackrel{iid}{\sim} N(0, \sigma_F^2), (VF)_{ik(j)} \stackrel{iid}{\sim} N(0, \sigma_{VF}^2), P_{m(ijk)} \stackrel{iid}{\sim} N(0, \sigma_P^2)$$

$$y_{r(ijkm)} \stackrel{iid}{\sim} N(0, \sigma_\epsilon^2),$$

incluyendo que todas las covarianzas entre estos efectos son iguales a cero.

Regla 2. Grados de Libertad

Los grados de libertad para cualquier efecto Q , notados $gl(Q)$, son obtenidos del diagrama de estructura por la distinción de factores vivos e inertes asociados con el efecto de interés. Hecha esta diferenciación, los grados de libertad resultan de multiplicar el rango de la matriz diseño asociada con los factores vivos disminuidos en uno por el rango de la matriz diseño asociada con los factores inertes.

Los grados de libertad, eliminando términos redundantes, se presentan en la tabla 4.1.

Tabla 4.1: Grados de libertad para el experimento tratado en la figura 4.2

C de V	gl
$V : \mu$	$n_v - 1$
$L : \mu$	$n_l - 1$
$VL : \mu$	$(n_v - 1)(n_l - 1) = n_v n_l - n_v - n_l + 1$
$F : L\mu$	$(n_f - 1)n_l = n_f n_l - n_l$
$VF : L\mu$	$(n_f - 1)(n_v - 1)n_l = n_f n_v n_l - n_f n_l - n_v n_l + n_l$
$P : VLF\mu$	$(n_p - 1)n_v n_f n_l = n_p n_v n_f n_l - n_v n_f n_l$
$\epsilon : PVFL\mu$	$(n_\epsilon - 1)n_p n_v n_f n_l = n_\epsilon n_p n_v n_f n_l - n_p n_v n_f n_l$

Regla 3. Sumas de Cuadrados

La suma de cuadrados para el efecto Q es obtenida por la multiplicación algebraica de los grados de libertad $gl(Q)$ en la suma de los términos $\sum [sig(t)]y_t$, en la que cada término t consiste de un conjunto de subíndices, signados de acuerdo con el resultado del producto de $gl(Q)$. La notación y_t indica el total de observaciones sobre el subíndice correspondiente asociado con t . Las expresiones algebraicas para las reglas (2) y (3) son $gl(Q) = \sum_t sig(t)$,

$$SC(Q) = \sum_{(2)} \left[\frac{sig(t)}{k(t)} \sum_{(1)} Y_t^2 \right],$$

donde (1) corresponde a la suma sobre todas las combinaciones de subíndices en t , (2) es la suma sobre todo t , $k(t)$ es el producto de los subíndices complementarios a los factores que aparecen en t ; o, de otra forma, es el producto de los rangos asociados con los factores cuyos subíndices no aparecen en t y $sig(t)$ hace referencia al signo asociado con el factor (t) .

El número de términos que resultan de la expansión de $g^l(Q)$ es 2^n , donde n es el orden del efecto. Para $n = 0$, es la media, para $n = 1$, un efecto principal, para $n = 2$, una interacción de segundo orden, y así sucesivamente.

De los resultados presentados para obtener los grados de libertad, pueden calcularse las sumas de cuadrados para cada uno de los efectos involucrados en el modelo. De la tabla 4.1, algunas sumas de cuadrados de interés son obtenidas como:

$$SC(V : \mu) = \frac{\sum_i y_{i.....}^2}{n_f n_p n_l n_\epsilon} - \frac{y_{.....}^2}{n_v n_l n_f n_p n_\epsilon}$$

$$SC(\mu) = \frac{y_{.....}^2}{n_v n_l n_f n_p n_\epsilon} = \text{Factor de corrección (FC)}$$

$$SC(L : \mu) = \frac{\sum_j y_{.j...}^2}{n_v n_f n_p n_\epsilon} - FC$$

$$SC(VL : \mu) = \frac{\sum_{ij} y_{ij...}^2}{n_f n_p n_\epsilon} - \frac{\sum_i y_{i.....}^2}{n_l n_f n_p n_\epsilon} - \frac{\sum_j y_{.j...}^2}{n_v n_f n_p n_\epsilon} + FC$$

De ese modo son calculadas todas las sumas de cuadrados.

Regla 4. Esperanza de los cuadrados medios

Los cuadrados medios esperados son calculados de acuerdo con los conceptos de factores e interacción ya expuestos. Los siguientes son los pasos a seguir:

- Paso 1. Formar el conjunto de las interacciones de factores vivos con interacciones de factores aleatorios complementarios de orden m . Luego se elabora una tabla y se escribe en la parte superior el índice y en la primera columna si el efecto es fijo o aleatorio.
- Paso 2. En cada fila se escribe uno si alguno de los subíndices inertes coincide con los subíndices de la columna.
- Paso 3. En cada fila, si cualquiera de los subíndices del componente del mismo coincide con el subíndice columna, se escribe cero si el factor es fijo y uno si es aleatorio.
- Paso 4. En las posiciones de la fila que quedan vacías se escribe el número de niveles del factor correspondiente en columna.
- Paso 5. Para obtener los cuadrados medios esperados de cualquier componente del modelo, primero se “tapa” cada columna cuyo encabezado es

subíndice vivo de ese componente. Enseguida, en cada fila que contiene al menos los mismos subíndices del componente en consideración, se elabora el producto de los factores visibles y se multiplica por el factor fijo o aleatorio. Finalmente, la suma de estas cantidades es el cuadrado medio esperado del componente en consideración.

Los coeficientes asociados con los factores vivos e inertes y las esperanzas de los cuadrados medios se presentan en las tablas 4.2 y 4.3.

Tabla 4.2: Coeficientes asociados con los factores vivos e inertes

Efecto	i	j	k	m	r
$F : V_i$	0	n_l	n_f	n_p	n_ϵ
$F : L_j$	n_v	0	n_f	n_p	n_ϵ
$F : VL_{ij}$	0	0	n_f	n_p	n_ϵ
$A : F_{k(j)}$	n_v	1	1	n_p	n_ϵ
$A : VF_{ik(j)}$	0	1	1	n_p	n_ϵ
$A : P_{m(ijk)}$	1	1	1	1	n_ϵ
$A : \epsilon_{r(ijkm)}$	1	1	1	1	1

Tabla 4.3: Esperanzas de los cuadrados medios para el caso tratado en la figura 4.2

C de V	E(CM)
V	$\sigma_\epsilon^2 + n_\epsilon \sigma_{p:vfl\mu}^2 + n_p n_\epsilon \sigma_{f:v:l\mu}^2 + [n_l n_f n_p n_\epsilon / (n_v - 1)] \sum_i v_i^2$
L	$\sigma_\epsilon^2 + n_\epsilon \sigma_{p:vfl\mu}^2 + n_v n_p n_\epsilon \sigma_{f:l\mu}^2 + [n_v n_f n_p n_\epsilon / (n_l - 1)] \sum_j l_j^2$
VL	$\sigma_\epsilon^2 + n_\epsilon \sigma_{p:vfl\mu}^2 + n_p n_\epsilon \sigma_{f:v:l\mu}^2 + [n_f n_p n_\epsilon / (n_v - 1)(n_l - 1)] \sum_{ij} (vl)_{ij}^2$
F	$\sigma_\epsilon^2 + n_\epsilon \sigma_{p:vfl\mu}^2 + n_v n_p n_\epsilon \sigma_{f:l\mu}^2$
FV	$\sigma_\epsilon^2 + n_\epsilon \sigma_{p:vfl\mu}^2 + n_p n_\epsilon \sigma_{f:v:l\mu}^2$
P	$\sigma_\epsilon^2 + n_\epsilon \sigma_{p:vfl\mu}^2$
ϵ	σ_ϵ^2

Regla 5. Construcción de las estadísticas F y estimación de los componentes de varianza

Con base en los resultados obtenidos en la regla 4, se desarrolla el análisis de varianza, se construyen las estadísticas de prueba F y la estimación de las diferentes componentes de varianza que conforman el modelo realizando los siguientes pasos:

Paso 1. $E(CM(Q)) = \sum k(s) \sigma_s^2 + \phi_s$, donde σ_s^2 es un componente de varianza para factores aleatorios, ϕ_s una desviación cuadrática media de

tratamientos para factores fijos y $k(s)$ es el producto de los complementos de s .

Paso 2. Construir el conjunto $S_l = \{l|l \text{ es una interacción de factores vivos con una interacción par de factores aleatorios complementarios simples (FACS)}\}$.

Paso 3. Formar $F_R = \{R|R \text{ es una interacción de los factores vivos con una interacción de orden impar de FACS}\}$.

$$F_Q = \frac{N_Q}{D_Q} = \frac{\sum CM(l)}{\sum CM(R)}.$$

Las razones F_Q siempre tendrán igual número de términos tanto en el numerador como en el denominador. Si solo hay un factor en FACS, habrá solo un término en N_Q y en D_Q , respectivamente. Si hay m términos en FACS, habrá 2^{m-1} términos en cada uno (numerador y denominador).

Paso 4. Del paso anterior, se sigue que en modelos con efectos cruzados y jerárquicos se satisface que

$$E(N_Q) - E(D_Q) = k(Q)\sigma_Q^2.$$

Paso 5. A partir del resultado anterior, se procede a la estimación de los componentes de varianza. La estimación del componente de varianza del efecto Q se obtiene mediante la siguiente expresión:

$$\hat{\sigma}_Q^2 = \frac{N_Q - D_Q}{k(Q)} = \frac{\sum CM(l) - \sum CM(R)}{k(Q)}$$

Para evaluar, por ejemplo, el efecto de planta en el modelo (4.1), la hipótesis de interés $H_0 : \sigma_{p:vl\mu}^2 = 0$, por ser un efecto aleatorio, tiene como estadístico de prueba

$$F_P = \frac{CM(P)}{CM(E)},$$

el cual se distribuye F con $(n_p - 1)n_v n_f n_l$ grados de libertad en el numerador y $(n_e - 1)n_p n_v n_f n_l$ en el denominador.

Si $F_P > F_{[(n_p-1)n_v n_f n_l; (n_e-1)n_p n_v n_f n_l; \alpha]}$, se rechaza $H_0 : \sigma_{p:vl\mu}^2 = 0$.

Adicionalmente, el componente de varianza del efecto planta se puede estimar como

$$\hat{\sigma}_{p:vl\mu}^2 = \frac{CM(P) - CM(E)}{n_e}$$

De esta manera, toda la información obtenida de la tradicional tabla de ANOVA puede ser obtenida visualmente a partir de un apropiado diagrama de estructura.

4.3. Ilustración del procedimiento

Algunos diagramas de interés práctico para la investigación experimental cuando se usan bloques son los presentados en las figuras 4.3, 4.4, 4.5 y 4.6, referenciados en Méndez (1981).




Figura 4.3: Arreglo en bloques completamente aleatorizados.

La figura 4.3 representa un arreglo en bloques completamente aleatorizados sobre cada una de varias localidades (L), con T tratamientos y R bloques.




Figura 4.4: Arreglo en bloques completamente aleatorizado sobre varias localidades y años (diferentes localidades para cada año).

La figura 4.4 representa un arreglo en bloques completamente aleatorizados sobre varias localidades y años (diferentes localidades para cada año), con T, L y R, como en el diagrama anterior, y A: μ efecto del año.




Figura 4.5: Diseño en bloques completamente aleatorizado sobre varias localidades y años.

La figura 4.5 representa un diseño en bloques completamente aleatorizados sobre varias localidades y años (algunas localidades para cada año, pero las unidades experimentales aleatorizadas sobre un cultivo anual).




Figura 4.6: Diagrama de un diseño en bloques completamente aleatorizado.

La figura 4.6 representa un diseño en bloques completamente aleatorizados sobre varias localidades y años (algunas localidades y unidades experimentales para cada año sobre un cultivo perenne).

De la figura 4.1(a), se tienen las siguientes causas de variación:

$$\begin{aligned} A &: \mu \\ \epsilon &: A\mu \end{aligned}$$

De esta forma se obtiene el modelo:

$$Y_{ij} = \mu + A_i + \epsilon_{ij}, \quad i = 1, \dots, n_a, \quad j = 1, \dots, n_\epsilon,$$

donde n_a hace referencia al número de veces que se repite el efecto de A , entonces las fuentes de variación y los grados de libertad que se obtienen para este diagrama son:

Causa de variación	gl
$A : \mu$	$n_a - 1$
$\epsilon : A\mu$	$(n_\epsilon - 1)n_a = n_a n_\epsilon - n_a$

Obsérvese que si $t = n_a$ es el número de tratamientos y $r = n_\epsilon$ es el número de repeticiones, los grados de libertad en la tabla de ANOVA se reducen a

Causa de variación	gl
$A : \mu$	$(t - 1)$
$\epsilon : A\mu$	$(t - 1)r$

Este arreglo caracteriza el *diseño completamente aleatorizado* balanceado con r repeticiones por tratamiento.

Un resultado importante en el análisis es el cálculo de los cuadrados medios esperados (E(CM)). Se ilustra a continuación, en un modelo sencillo, el cálculo de la esperanza de los cuadrados medios esperados.

Suponiendo la figura 4.1(b), se caracteriza el modelo

$$Y_{ijk} = \mu + A_i + B_j + (AB)_{ij} + \epsilon_{k(ij)},$$

donde $i = 1, \dots, n_a$, $j = 1, \dots, n_b$, $k = 1, \dots, n_\epsilon$.

Si el único efecto aleatorio es el error, se obtiene

Característica	Efecto	gl	i	j	k	E(CM)
F	A_i	$n_a - 1$	0	n_b	n_ϵ	$\sigma^2 + n_b n_\epsilon \tau(A)$
F	B_j	$n_b - 1$	n_a	0	n_ϵ	$\sigma^2 + n_a n_\epsilon \tau(B)$
F	AB_{ij}	$(n_a - 1)(n_b - 1)$	0	0	n_ϵ	$\sigma^2 + n_\epsilon \tau(AB)$
A	$\epsilon_{k(ij)}$	$(n_\epsilon - 1)n_a n_b$	1	1	1	σ^2

donde $\tau(A) = \frac{1}{n_a - 1} \sum a_i^2$, con a_i la estimación del efecto A_i . De forma similar, se obtienen $\tau(B)$ y $\tau(AB)$.

En el ejemplo 4.1, se muestra el cálculo de la esperanza de cuadrados medios para un experimento más complejo.

Ejemplo 4.1. Suponga que se tiene un grupo de tratamientos para ensayar en diversas localidades y diversos años, y las posibles combinaciones de estos tres factores son ensayadas en diferentes plantas. Para este ensayo, se ilustra en la figura 4.7 su respectivo diagrama.

El modelo asociado con la figura 4.7 es:

$$Y_{ijks} = \mu + T_i + L_j + A_k + (TL)_{ij} + (TA)_{ik} + (LA)_{jk} + (TLA)_{ijk} + \epsilon_{s(ijk)},$$

donde $i = 1, \dots, I$, $j = 1, \dots, J$, $k = 1, \dots, K$, $s = 1, \dots, S$.




Figura 4.7: Diagrama de estructura para el ejemplo 4.1.

Suponiendo que solo el efecto del tratamiento es un efecto fijo y el resto de componentes del modelo es aleatorio, esto es, $L_j \stackrel{iid}{\sim} N(0, \sigma_L^2)$, $A_k \stackrel{iid}{\sim} N(0, \sigma_A^2)$, $(TL)_{ij} \stackrel{iid}{\sim} N(0, \sigma_{TL}^2)$, $(LA)_{jk} \stackrel{iid}{\sim} N(0, \sigma_{LA}^2)$, $(TA)_{ik} \stackrel{iid}{\sim} N(0, \sigma_{TA}^2)$, $(TLA)_{ijk} \stackrel{iid}{\sim} N(0, \sigma_{TLA}^2)$ y $\epsilon_{s(ijk)} \stackrel{iid}{\sim} N(0, \sigma_\epsilon^2)$.

Además, se supone que los factores no están relacionados, es decir, $Cov(L_j, A_k) = 0 \forall j, k, \dots, Cov((TLA)_{ijk}, \epsilon_{s(ijk)}) = 0 \forall i, j, k, s$.

En la tabla 4.4 se obtienen los cuadrados medios esperados según las reglas propuestas.

De la tabla 4.4, los cuadrados medios esperados pueden resumirse así:

En la columna de las E(CM), una forma práctica de determinar la combinación del efecto es observando si el subíndice del efecto o interacción está contenido en los subíndices de las interacciones de orden superior; entonces la componente debe aparecer como una combinación de los componentes de varianza del efecto.

De la tabla 4.4, se observa que para probar los efectos de

i Tratamientos: la hipótesis de interés es $H_0^t: \mu_{T_1} = \dots = \mu_{T_I}$, la cual tiene como estadístico de prueba

$$F_t = \frac{CM(T : \mu) + CM(TLA : \mu)}{CM(TL : \mu) + CM(TA : \mu)} = \frac{V_1 + V_2}{V_3 + V_4},$$

donde $V_1 = CM(T : \mu)$, $V_2 = CM(TLA : \mu)$, $V_3 = CM(TL : \mu)$ y $V_4 = CM(TA : \mu)$, con n'_1 y n'_2 grados de libertad.

Para obtener los grados de libertad apropiados, se usa la aproximación propuesta por Satterthwaite (1946), obteniéndose

$$n'_1 = \frac{(V_1 + V_2)^2}{\frac{V_1^2}{I-1} + \frac{V_2^2}{(I-1)(J-1)(K-1)}}$$

Tabla 4.4: Cuadrados medios esperados para los datos del ejemplo 4.1

Caracte- rística	Letra efecto	i	j	k	s	E(CM)
F	$T_i : \mu$	0	J	K	S	$\sigma^2 + S\sigma_{TLA}^2 + JS\sigma_{TA}^2 + KS\sigma_{TL}^2 + \frac{JKS}{(I-1)} \sum T_i^2$
A	$L_j : \mu$	I	1	K	S	$\sigma^2 + IS\sigma_{LA}^2 + IKS\sigma_L^2$
A	$A_k : \mu$	I	J	1	S	$\sigma^2 + IS\sigma_{LA}^2 + IJS\sigma_A^2$
A	$TL_{ij} : \mu$	0	1	K	S	$\sigma^2 + S\sigma_{TLA}^2 + KS\sigma_{TL}^2$
A	$TA_{ik} : \mu$	0	J	1	S	$\sigma^2 + S\sigma_{TLA}^2 + JS\sigma_{TA}^2$
A	$LA_{jk} : \mu$	I	1	1	S	$\sigma^2 + IS\sigma_{LA}^2$
A	$TLA_{ijk} : \mu$	0	1	1	S	$\sigma^2 + S\sigma_{TLA}^2$
A	$\epsilon_{s(ijk)} : \mu TLA$	1	1	1	1	σ^2

$$n'_2 = \frac{(V_3 + V_4)^2}{\frac{V_3^2}{(I-1)(J-1)} + \frac{V_4^2}{(I-1)(K-1)}}.$$

Se rechaza H_0^t si $F_t > F_{(n'_1, n'_2, \alpha)}$ a un nivel de significación de 100α %.

ii Localidades: la hipótesis de interés sobre localidades es $H_0^l : \sigma_L^2 = 0$ y la estadística de prueba está dada por

$$F_l = \frac{CM(L : \mu)}{CM(LA : \mu)}.$$

Si este valor es mayor que $F_{[(J-1), (J-1)(K-1), \alpha]}$, entonces se rechaza $H_0^l : \sigma_L^2 = 0$ a un nivel de significación de 100α %. Además, la componente de varianza se puede estimar realizando el siguiente proceso

$$E(CM(L)) - E(CM(LA)) = IKS\sigma_L^2.$$

Por lo tanto,

$$\hat{\sigma}_L^2 = \frac{CM(L) - CM(LA)}{IKS}.$$

iii Años: la hipótesis a probar en este caso es $H_0^a : \sigma_A^2 = 0$. La estadística de prueba está dada por:

$$F_a = \frac{CM(A : \mu)}{CM(LA : \mu)},$$

entonces se rechaza H_0^a si $F_a > F_{[K-1, (J-1)(K-1), \alpha]}$ a un nivel de significación de 100α %.

La componente de varianza, σ_A^2 , se obtiene de la siguiente forma

$$E(CM(A)) - E(CM(LA)) = IJS\sigma_A^2.$$

Por consiguiente,

$$\hat{\sigma}_A^2 = \frac{CM(A) - CM(LA)}{IJS}.$$

Ejemplo 4.2. Diseño completamente aleatorizado con submuestreo. Los datos tomados de Peterson (1985) hacen referencia a un ensayo de tres productos químicos tendientes a retardar la expansión del fuego cuando es usado en el tratamiento de paneles para piso de madera. El investigador obtiene 12 paneles y aplica cada uno de los productos a cuatro de ellos. Se cortan dos piezas de cada panel y se mide el tiempo requerido por cada uno de ellos para ser consumido por el fuego. Los resultados de este ensayo se presentan en la tabla 4.5.

Nótese que la variable respuesta mide el tiempo en minutos en que es consumida la pieza de madera por el fuego.

Tabla 4.5: Tiempos de consumo por el fuego de piezas de madera

Panel	Muestra	Producto químico		
		A	B	C
1	1	10.3	4.4	3.1
	2	9.8	4.7	3.3
		(20.1)	(9.1)	(6.4)
2	1	5.8	2.7	6.5
	2	5.4	1.6	5.4
		(11.2)	(4.3)	(11.9)
3	1	8.7	4.6	5.1
	2	10.0	4.0	7.5
		(18.7)	(8.6)	(12.6)
4	1	8.9	5.6	5.6
	2	9.4	3.4	4.2
		(18.3)	(9.0)	(9.8)
Total	$y_{i..}$	68.3	31	40.7

El diagrama de estructura asociado con el problema en cuestión se presenta en la figura 4.8.




Figura 4.8: Diagrama de estructura para el ejemplo 4.2.

El modelo lineal asociado con la figura 4.8 para el conjunto de datos es

$$y_{ijk} = \mu + P_i + \epsilon_{j(i)} + \eta_{k(ij)}, \quad (4.2)$$

donde $i = 1, 2, 3$, $j = 1, 2, 3, 4$, $k = 1, 2$.

En tabla 4.6, los grados de libertad y la esperanza de los cuadrados medios asociados con el modelo 4.2.

Tabla 4.6: Grados de libertad y esperanzas de los cuadrados medios asociados con los datos del ejemplo 4.2

Causas de variación	gl	I	J	K	E(CM)
$P_i : \mu$	$I - 1$	0	J	K	$\sigma_\eta^2 + K\sigma_\epsilon^2 + JK \sum_i \frac{P_i^2}{(I-1)}$
$EE_{j(i)} : \mu P$	$(J - 1)I$	1	1	K	$\sigma_\eta^2 + K\sigma_\epsilon^2$
$EM_{k(ij)} : \mu P\epsilon$	$(K - 1)IJ$	1	1	1	σ_η^2
Total	$IJK - 1$				

Las sumas de cuadrados asociadas con cada uno de los términos involucrados en el modelo son

$$\begin{aligned}
 SC(\text{producto}) &= \frac{1}{KJ} \sum_i y_{i..}^2 - \frac{y_{...}^2}{IJK} \\
 &= \frac{1}{8} [68.3^2 + 31^2 + 40.7^2] - \frac{140^2}{24} \\
 &= 93.63 \\
 SC(EE) &= \frac{1}{K} \sum_i \sum_j y_{ij.}^2 - \frac{1}{KJ} \sum_i y_{i..}^2 \\
 &= \frac{1}{2} [20.1^2 + \dots + 9.8^2] - \frac{1}{8} (7282.38) \\
 &= 43.53 \\
 SC(EM) &= \sum_i \sum_j \sum_k y_{ijk}^2 - \frac{1}{K} \sum_i \sum_j y_{ij.}^2 \\
 &= [10.3^2 + \dots + 4.2^2] - \frac{1}{2} (1907.06) \\
 &= 8.91.
 \end{aligned}$$

De la tabla 4.7 de análisis de varianza, se asume la hipótesis $H_0 : \mu_A = \mu_B = \mu_C$, es decir, que la conclusión se saca únicamente sobre la igualdad del efecto medio de los tres productos químicos. Sin embargo, también se puede, a partir de los resultados obtenidos, contrastar la hipótesis $H_0 : \sigma_\epsilon^2 = 0$.

Según los resultados de la tabla 4.7, como $F_{PQ} = 9.68 > F_{(2,9,0.05)} = 4.25$, entonces se rechaza la hipótesis nula de igualdad entre los tiempos promedios del retardo del consumo por el fuego de piezas de madera al ensayar los tres productos químicos. Además, como $F_{EE} = 6.51 > F_{(9,12,0.05)} = 2.79$, no hay evidencia para aceptar la hipótesis $H_0 : \sigma_\epsilon^2 = 0$, con lo cual se corrobora la importancia de hacer submuestreo en este experimento.

Tabla 4.7: Análisis de varianza para los datos del ejemplo 4.2

Causas de variación	G.L.	SC	CM	E(CM)	F
Producto químico	2	93.63	46.82	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2 + 8 \sum_i \frac{P_i^2}{2}$	9.68
Error experimental	9	43.53	4.83	$\sigma_{\eta}^2 + 2\sigma_{\epsilon}^2$	6.51
Error muestreo	12	8.91	0.74	σ_{η}^2	
Total	23				

La estimación de los componentes de la varianza arrojó los siguientes resultados, realizando el procedimiento de estimación propuesto por Henderson (1953).

$$\hat{\sigma}_{\eta}^2 = CM(EM) = 0.74$$

$$\hat{\sigma}_{\epsilon}^2 = \frac{1}{2}[CM(EF) - CM(EM)] = 2.05.$$

4.4. Implementación en SAS

Cuando se tiene un modelo de efectos fijos, se debe emplear el procedimiento GLM o ANOVA del SAS; cuando es de efectos mixtos, se debe emplear el procedimiento MIXED del SAS, y cuando los efectos son todos de tipo aleatorio, se debe utilizar el procedimiento VARCOM del SAS. El programa en el paquete estadístico SAS a través del cual se obtuvieron los resultados expuestos en el conjunto de datos del ejemplo 4.2 es el siguiente:

```

TITLE `Estudio de los productos químicos';
DATA EJEMPLO42; /*archivo del ejemplo 4.2*/
DO PANEL=1 TO 4;
    DO MUESTRA=1 TO 2;
        DO PRODUCTO=1 TO 3;
            INPUT TIEMPO @@; OUTPUT;
        END;
    END;
END;
CARDS; /* Lectura de los datos*/
10.3 4.4 3.1 9.8 4.7 3.3 5.8 2.7 6.5 5.4 1.6 5.4
8.7 4.6 5.1 10.0 4.0 7.5 8.9 5.6 5.6 9.4 3.4 4.2
;
PROC PRINT DATA=EJEMPLO42;

*Análisis de varianza haciendo uso del procedimiento GLM*/
PROC GLM DATA=EJEMPLO42;
CLASS PRODUCTO PANEL;
MODEL TIEMPO=PRODUCTO PANEL(PRODUCTO);
RANDOM PANEL(PRODUCTO)/TEST; /*Se define como aleatoria la unidad

```

experimental panel dentro de producto y a través de la opción TEST se obtienen las pruebas estadísticas correctas*/

```
/*Análisis de varianza para un modelo mixto*/
PROC MIXED DATA=EJEMPL042;
CLASS PRODUCTO PANEL;
MODEL TIEMPO=PRODUCTO; /*Se colocan los efectos fijos involucrados en el
modelo*/
RANDOM PANEL(PRODUCTO);

/*Análisis de varianza para un modelo de efectos aleatorios, en este caso,
suponiendo que el Panel es aleatorio*/
PROC VARCOMP DATA=EJEMPL042 METHOD=REML;
/*ML MIVQUE0 TYPE1 TYPE2 TYPE3*/
/*METHOD define el método de estimación de las componentes de varianza*/
CLASS PRODUCTO PANEL;
MODEL TIEMPO=PRODUCTO PANEL(PRODUCTO);
RUN;
```

4.5. Implementación en R

A partir de los datos del ejemplo 4.2, se presenta a continuación el programa en el software estadístico R.

```
#####
## Ejemplo 4.2 ##
#####

#Introducción de los datos del ejemplo

ejemplo4.2 <- data.frame(panel=factor(rep(c(rep(1,2),rep(2,2),rep(3,2),
rep(4,2)),3)),muestra=factor(rep(c(1,2),12)),
sujeito=factor(rep(c(rep(1,2),rep(2,2),rep(3,2),rep(4,2),rep(5,2),rep(6,2),
rep(7,2),rep(8,2),rep(9,2),rep(10,2),rep(11,2),rep(12,2)))),
producto=factor(c(rep(1,8),rep(2,8),rep(3,8))),tiempo=c(10.3,9.8,5.8,5.4,8.7,
10,8.9,9.4,4.4,4.7,2.7,1.6,4.6,4,5.6,3.4,3.1,3.3,6.5,5.4,5.1,7.5,5.6,4.2))

# Tabla de Anova dca con submuestreo
dca1 <- aov(tiempo~producto+Error(sujeito),data=ejemplo4.2)
summary(dca1)

# Prueba de normalidad residuales
shapiro.test(summary(lm(dca1))$residuals)
# Anova con submuestreo la mejor opción
library(EMSaov)
EMSanova(tiempo~producto+panel, data=ejemplo4.2, type = c("F", "R"),
          nested = c(NA,'producto'),level = c(3, 4))
```



```
# Otra forma de sumas de cuadrados
dca2<-aov(tiempo~producto+panel%in%producto+muestra%in%panel%in%producto,
data=ejemplo4.2)
summary(dca2)
# Estimación de las componentes de varianza
library(lme4)
dca3<-lmer(tiempo~producto+(1|panel:producto),data=ejemplo4.2)
summary(dca3)

# Corroboración de las estimaciones de las componentes de varianza
varee<-1/2*(4.84-0.7425) #varianza del error experimental
vartotal<-varee+0.7425
r1<-varee/vartotal # coeficiente de correlación intraclase del error exp
r2<-0.7425/vartotal # coeficiente de correlación intraclase del error muestral
```

4.6. Ejercicios

1. Suponga el modelo $y_{ijk} = \mu + b_i + a_{j(i)} + \epsilon_{k(ij)}$, donde $k = 1, \dots, t$, $j = 1, \dots, r$, $i = 1, \dots, m$. Suponga que el único efecto aleatorio es el error experimental.
 - a. Presente el diagrama de estructura para llevar a cabo el análisis de este experimento especificando el modelo propuesto.
 - b. Lleve a cabo el ANOVA especificando los grados de libertad, la suma de cuadrados, las esperanzas de los cuadrados medios y los estadísticos de prueba para las hipótesis de interés.
2. Para los ejercicios 5 al 8 del capítulo 1,
 - a. Presente el diagrama de estructura para llevar a cabo el análisis de cada experimento.
 - b. Lleve a cabo el ANOVA especificando los grados de libertad, la suma de cuadrados, las esperanzas de los cuadrados medios, y pruebe la hipótesis de interés.
3. Suponga que (V) variedades de una leguminosa fueron plantadas en diferentes fechas (F). De cada combinación fecha-variedad, fueron seleccionadas algunas plantas (P) y ciertas hojas (L) fueron seleccionadas aleatoriamente de cada planta. Cada hoja fue analizada por un número de métodos estándar (M) por diferentes analistas (R).

- a. Presente el diagrama de estructura y su modelo asociado para llevar a cabo el análisis de este experimento.
 - b. Presente la tabla de análisis de varianza.
4. Un experimento de caña de azúcar fue diseñado de tal modo que se ensayaron los nutrientes mayores N , P y K con las siguientes dosis 0 y 200, 0 y 100, 0 y 80 Kgs/Ha, respectivamente (Martínez 1988). El área experimental era bastante uniforme y lo suficientemente grande como para que el material experimental se ensayará en tres oportunidades. La respuesta observada fue el rendimiento (Kgs/Área de 44 m²):
 - a. Encuentre el diagrama de estructura apropiado.
 - b. Obtenga el modelo apropiado señalando todos los supuestos necesarios que permitan realizar pruebas de hipótesis de efectos principales e interacciones.
 - c. Construya la tabla ANOVA completa (gl , SC y prueba F).
 - d. Obtenga un estimador de varianza para el error experimental.
5. Suponga un estudio donde se tiene el factor estado, el municipio, la localización (rural-urbana) y las casas, en el cual se desea estudiar la presencia de agentes patógenos en la familia.
 - a. Presente el diagrama de estructura asociado con este estudio.
 - b. Encuentre el modelo apropiado para el diagrama obtenido en a.
 - c. Presente la tabla de análisis de varianza suponiendo que el factor municipio es aleatorio, estructurando apropiadamente las sumas de cuadrados, esperanzas de los cuadrados medios y las pruebas F .
6. En un estudio sobre crecimiento, desarrollo y adaptación de 6 materiales de sorgo a las condiciones de los llanos orientales, se usó un diseño en bloques completos aleatorizados con 6 genotipos, 3 replicaciones y 5 plantas por replicación.
 - a. Presente el diagrama de estructura apropiado.
 - b. Presente el modelo adecuado señalando todos los supuestos necesarios que permitan realizar pruebas de hipótesis de efectos principales.
 - c. Construya la tabla ANOVA completa.

7. Considere la estructura balanceada, en la cual se tienen 4 factores A , B , C y D , donde A y B son cruzados, C está anidado en AB y D está anidado en C .
 - a. Presente el diagrama de estructuras.
 - b. Presente el modelo en notación estándar.
 - c. Escriba la tabla ANOVA, incluyendo la esperanza de los cuadrados medios suponiendo todos los factores fijos.

Capítulo
cinco
**Diseños
completamente
aleatorizados y
tamaño de
muestra**

5.1. Diseño completamente aleatorizado

Cuando los tratamientos se ensayan en condiciones homogéneas del material experimental, es decir, las *unidades experimentales* (UE) son homogéneas (tienen en principio igual capacidad de respuesta), y cuando solo se tiene como factor de clasificación los tratamientos y la asignación de estos a las UE, se hace en forma aleatoria (aleatorización irrestricta), entonces el modelo caracteriza el *Diseño completamente aleatorizado* (DCA). En este diseño se supone que si se tiene $n = tr$, UE's homogéneas, entonces se pueden particionar las unidades experimentales dentro de t conjuntos de r unidades cada uno. Además, cada UE tiene igual probabilidad de asignación a cualquiera de los conjuntos de tratamientos. Este procedimiento define el DCA para t tratamientos. La realización de este protocolo es llamado en Hinkelmann y Kempthorne (1994) *experimento completamente aleatorizado con igual número de réplicas*.

De lo anterior, es claro que se tiene un diseño aleatorizado si y solo si se ha realizado una asignación aleatoria de los tratamientos a las UE. El siguiente ejemplo de un DCA es un problema típico para ilustrar este arreglo y el análisis de un experimento.

Ejemplo 5.1. *Se llevo a cabo un estudio para evaluar cuatro dietas (D_1 , D_2 , D_3 , D_4), con el propósito de comparar la efectividad de la dieta en la pérdida de peso en personas que asisten a un gimnasio. La dieta se suministró durante 30 días; la población es el conjunto de personas que asisten al gimnasio. El factor de análisis o variable explicativa es la dieta (tratamiento). La forma de medir la efectividad de la dieta se hace mediante la evaluación de la pérdida o ganancia de peso (diferencia entre peso final y peso inicial) para cada uno de las personas incluidas en el experimento. Esta ganancia o pérdida es la variable respuesta que se obtiene de cada persona tratada, siendo estas las correspondientes unidades experimentales.*

Para este estudio se seleccionaron 20 personas y se asignaron aleatoriamente 5 a cada dieta. Para que el diseño sea completamente aleatorizado, se requiere primero seleccionar una muestra aleatoria de 20 personas de la población y segundo distribuir las dietas a las personas también en forma aleatoria. La teoría de muestreo dice cómo seleccionar las 20 personas conocida cierta información sobre la conformación de la población, tal como el acceso de las personas al gimnasio, el tiempo que dura la investigación, etc.

Si la llegada de personas al gimnasio es frecuente, podrán seleccionarse las 20 personas entre las 100 o 300 que ingresan, utilizando una tabla de números aleatorios o generando estos a partir del uso de algún Software estadístico. Si la disponibilidad

de personas es menor, podría seguirse un muestreo sistemático, por ejemplo, una de cada dos o una de cada tres que llegan.

Una vez obtenida la muestra, se numeran las personas o unidades experimentales en el orden de selección como $v_1, v_2, \dots, v_{20}$ para asignarles los respectivos tratamientos. Esta asignación debe ser aleatoria y una de las muchas formas posibles de hacerlo es la siguiente:

1. Se numeran las dietas como D_1, D_2, D_3 y D_4 .
2. Mediante la generación de números aleatorios, se asigna una dieta a cada persona. A partir de este proceso, se puede generar entre muchas alternativas para la realización del problema un arreglo como el de la tabla 5.1.

Tabla 5.1: Asignación aleatoria de 4 dietas a 20 unidades experimentales

Réplica	D_1	D_2	D_3	D_4
1	v_7	v_1	v_{10}	v_8
2	v_{11}	v_2	v_4	v_{19}
3	v_{12}	v_6	v_{15}	v_5
4	v_{17}	v_{14}	v_{13}	v_9
5	v_{18}	v_3	v_{16}	v_{20}

3. Cuando una dieta o tratamiento ha recibido todas las unidades, este es ignorado al continuar con el proceso de aleatorización. Este procedimiento no es pertinente en el caso de grupos desiguales.

Dos de las ventajas del DCA son: i) es flexible, se ajusta a cualquier número de tratamientos, cada uno con igual o diferente número de réplicas, y ii) las observaciones perdidas no crean dificultades en el análisis. La principal desventaja es que exige una muestra homogénea, la cual es difícil de obtener cuando hay muchos tratamientos y/o muchas réplicas.

Al realizar el experimento presentado en el ejemplo 5.1, se tiene la pérdida o ganancia de peso en kilogramos de las personas que asisten al gimnasio. Los datos obtenidos se muestran en la tabla 5.2.

5.2. Principios del análisis de varianza

El análisis de varianza fue propuesto inicialmente por Fisher y publicado en 1923. Cinco años antes, había usado los términos de varianza y análisis de varianza no para estudiar la varianza propiamente sino la variación experimental. Tal como se conoce hoy día, el análisis de varianza es una técnica y procedimiento estadístico que permite la descomposición de las

diferentes fuentes de variación para analizar datos provenientes de un experimento aleatorio. No es un método fijo, por el contrario, se adapta a cada diseño particular.

Tabla 5.2: Pérdida o ganancia de peso en kilogramos de 20 personas que asistieron a un gimnasio al aplicarles una dieta

Réplica	D_1	D_2	D_3	D_4
1	-9.3	-10.1	1.5	-3.2
2	2.5	-5.0	-2.0	-5.6
3	-5.4	-7.2	-0.5	-8.4
4	-3.6	-9.2	3.4	-5.3
5	1.7	-8.1	-2.5	-1.4
Totales	-14.1	-39.6	-0.1	-23.9
Medias	-2.82	-7.92	-0.02	-4.78
Varianzas	24.5	3.87	6.08	6.99

Si el diseño es unifactorial, se aplica ANOVA de clasificación simple o de una vía. Si es multifactorial, el ANOVA correspondiente será de dos vías (dos factores), de tres vías (tres factores), etc. Si se tiene un factor y una variable de agrupación (diseño de bloques), el ANOVA también es de dos vías. Si se tiene un factor y dos variables de agrupación (diseño de cuadro latino), el ANOVA será de tres vías. Esto se generaliza al caso de n -vías de clasificación como se describió en el capítulo 1.

De acuerdo con el número de réplicas, se obtiene el ANOVA con grupos iguales para diseños balanceados (igual número de réplicas por tratamiento) y el ANOVA con grupos desiguales (diferente número de réplicas por tratamiento).

La forma de seleccionar los niveles de los factores también determina el tipo de análisis. Si los niveles son fijos o escogidos de antemano por el investigador, se habla del modelo I de ANOVA o modelo de efectos fijos. Si los niveles son seleccionados aleatoriamente de un grupo grande (población), se aplica el modelo II o modelo de efectos aleatorios, también llamado modelo de componentes de varianza. El modelo III o modelo mixto es usado cuando hay factores con niveles fijos y factores con niveles aleatorios en el experimento. La clasificación I, II o III en este concepto se debe a Eisenhart (1947).

El objetivo central del diseño experimental es la comparación de dos o más tratamientos cada uno de los cuales representa una población como es usual en experimentos comparativos. Si, por ejemplo, se tiene un factor A con t niveles o tratamientos, y cada uno de ellos está repetido r veces en el

experimento, cada unidad experimental produce una observación, la cual se analiza con base en un modelo estadístico llamado *modelo lineal aditivo*.

El análisis de un experimento está basado normalmente en un modelo matemático para las observaciones, y este modelo matemático está relacionado y justificado por el diseño. Se puede asegurar que la aleatorización es el paso que introduce los modelos probabilísticos para el análisis de información. Este hecho fue observado inicialmente por Fisher y es considerado actualmente como una de sus mayores contribuciones al desarrollo de la ciencia.

A continuación se mostrará la caracterización matemática a través de la formulación de un modelo lineal, tanto con el uso del modelo superparametrizado como por el modelo de medias de celdas.

En el proceso de aleatorización de las UE en un DCA se puede tener $s = \frac{n!}{(r!)^t} = \frac{(tr)!}{(r!)^t}$ posibles planes. Un posible plan puede tener el arreglo del material experimental mostrado en la tabla 5.3.

Tabla 5.3: Estructura de los datos para un ANOVA a una vía de clasificación

Réplicas	Niveles del factor A (tratamientos)					
	1	2	...	i	...	t
1	y_{11}	y_{21}	...	y_{i1}	...	y_{t1}
2	y_{12}	y_{22}	...	y_{i2}	...	y_{t2}
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$
j	y_{1j}	y_{2j}	...	y_{ij}	...	y_{tj}
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$
r_i	y_{1r_i}	y_{2r_i}	...	y_{ir_i}	...	y_{tr_i}
Total	$y_{1.}$	$y_{2.}$	...	$y_{i.}$	...	$y_{t.}$
Observ.	r_1	r_2	...	r_i	...	r_t
Medias	$\bar{y}_{1.}$	$\bar{y}_{2.}$	...	$\bar{y}_{i.}$	...	$\bar{y}_{t.}$

En este caso, y_{ij} es la j -ésima replicación asociada con el i -ésimo tratamiento. El punto como subíndice indica que se suma sobre el subíndice que está reemplazando, por ejemplo, $y_{i.} = \sum_{j=1}^{r_i} y_{ij}$, $y_{.j} = \sum_{i=1}^t y_{ij}$, $\bar{y}_{i.} = \frac{1}{r_i} \sum_{j=1}^{r_i} y_{ij}$,

$$\bar{y}_{.j} = \frac{1}{t} \sum_{i=1}^t y_{ij} \text{ y } \bar{y}_{..} = \frac{1}{n} \sum_{i=1}^t \sum_{j=1}^{r_i} y_{ij}, \text{ con } n = \sum_{i=1}^t r_i.$$

Para el caso particular de un DCA (efectos fijos y un factor), el modelo estadístico es caracterizado por

$$y_{ij} = \mu_i + \epsilon_{ij}, \quad (5.1)$$

con $i = 1, \dots, t$ (tratamientos), $j = 1, \dots, r_i$ (número de réplicas en el tratamiento i -ésimo), μ_i es la media de la población i -ésima y ϵ_{ij} es el error experimental aleatorio asociado con la observación y_{ij} .

En el modelo (5.1), cada y_{ij} es una variable aleatoria, lo mismo que los errores ϵ_{ij} , mientras que los μ_i son parámetros.

Cuando $\mu_i = \mu + \alpha_i$ en (5.1) caracteriza el modelo superparametrizado,

$$y_{ij} = \mu + \alpha_i + \epsilon_{ij}, \quad (5.2)$$

donde μ es la media global de las poblaciones combinadas y α_i va a medir el efecto producido por el tratamiento i -ésimo.

Para hacer estimaciones y pruebas de hipótesis sobre los parámetros μ_i , μ y α_i en los modelos (5.1) y (5.2), respectivamente, es necesario establecer algunas condiciones mínimas. Estas son:

1. Los errores ϵ_{ij} son independientes y tienen distribución normal $N(0, \sigma^2)$.
2. Cada tratamiento define una población con distribución normal $N(\mu_i, \sigma^2)$; la varianza σ^2 es constante e igual para todos los tratamientos (varianzas homogéneas).
3. La media μ_i para el tratamiento i puede descomponerse como $\mu_i = \mu + \alpha_i$. Para estimar en forma única los parámetros μ_i , se requiere, además, que $\sum_{i=1}^t r_i \alpha_i = 0$.

5.3. DCA a través del modelo superparametrizado

Para el modelo (5.2), la hipótesis del análisis de varianza de una vía de clasificación y efectos fijos se refiere a la comparación de la igualdad de efectos de tratamientos, o sea, $H_0 : \alpha_1 = \dots = \alpha_t$ versus $H_a : \text{al menos un par de } \alpha_i \text{'s es diferente}$ ($i = 1, \dots, t$) si $n = \sum_{i=1}^t r_i$. Entonces la matriz de proyección

$$\mathbf{P}_X = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t = \text{BloqDiag} \left(\frac{1}{r_i} \mathbf{J}_{r_i \times r_i} \right),$$

donde $\mathbf{X} = [\mathbf{1}_n : \text{Diag}(\mathbf{1}_{r_i})]$, $\mathbf{1}_n$ es un vector de unos de tamaño n , $\mathbf{1}_{r_i}$ es un vector de unos de tamaño r_i , $\text{BloqDiag}(\cdot)$ es una matriz diagonal por bloques y $\mathbf{J}_{r_i \times r_i}$ es una matriz de unos de orden $r_i \times r_i$.

La matriz de proyección anterior, satisface:

i) $P_X Y = (t_{ij})$, con $t_{ij} = \bar{y}_{i.}$, $i = 1, \dots, t$.

ii) $P_\alpha Y = (u_{ij})$, con $u_{ij} = \bar{y}_{i.} - \bar{y}_{..}$, $i = 1, \dots, t$,

siendo $P_\alpha = P_X - \frac{1}{n} J_{n \times n}$. Específicamente, los dos resultados anteriores llevan a

$$P_X Y = [\bar{y}_{1.}, \dots, \bar{y}_{1.}, \bar{y}_{2.}, \dots, \bar{y}_{2.}, \dots, \bar{y}_{t.}, \dots, \bar{y}_{t.}]^t,$$

donde cada uno de los $\bar{y}_{i.}$ es un vector de tamaño r_i , $i = 1, \dots, t$,

$$P_\alpha Y = [\bar{y}_{1.} - \bar{y}_{..}, \dots, \bar{y}_{1.} - \bar{y}_{..}, \dots, \bar{y}_{t.} - \bar{y}_{..}, \dots, \bar{y}_{t.} - \bar{y}_{..}]^t$$

y

$$X\theta = [\mu + \alpha_1, \dots, \mu + \alpha_1, \dots, \mu + \alpha_t, \dots, \mu + \alpha_t]^t.$$

De la definición 3.1 de estimabilidad, se tiene que

$$a^t = [0, \dots, 0, 1, 0, \dots, 0].$$

Con esto, sin pérdida de generalidad, demuestra que $\mu + \alpha_i = a^t X\theta$ es una función paramétrica estimable y, además,

$$MELI(\mu + \alpha_i) = (\hat{\mu} + \hat{\alpha}_i) = \bar{y}_{i.}, \quad i = 1, \dots, t.$$

Una forma de realizar el análisis es imponer algunas condiciones de estimabilidad y, de esta forma, establecer funciones estimables. Una condición usual es asumir $\sum_{i=1}^t r_i \alpha_i = 0$, con lo cual se tiene que $\mu = \frac{1}{n} \sum_{i=1}^t r_i (\mu + \alpha_i)$. Este parámetro tiene como estimador a

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^t r_i (\hat{\mu} + \hat{\alpha}_i) = \frac{1}{n} \sum_{i=1}^t \frac{r_i}{r_i} \sum_{j=1}^{r_i} y_{ij} = \bar{y}_{..}$$

Similarmente,

$$\hat{\alpha}_i = \hat{\mu} + \hat{\alpha}_i - \hat{\mu} = \bar{y}_{i.} - \bar{y}_{..},$$

de donde se concluye que $\hat{\mu} + \hat{\alpha}_i = \bar{y}_{i.}$.

El análisis de varianza se origina de la partición de la suma de cuadrados corregida por la media en dos sumas de cuadrados independientes: una, debida a la variabilidad entre los tratamientos, y la otra, debida a la variación dentro tratamientos.

Lo anterior se puede expresar como:

$$\sum_{i=1}^t \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{..})^2 = \sum_{i=1}^t \sum_{j=1}^{r_i} (\bar{y}_{i.} - \bar{y}_{..})^2 + \sum_{i=1}^t \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i.})^2. \quad (5.3)$$

En términos matriciales

$$\mathbf{Y}^t \left(\mathbf{I}_n - \frac{1}{n} \mathbf{J}_n \right) \mathbf{Y} = \mathbf{Y}^t \left(\mathbf{P}_X - \frac{1}{n} \mathbf{J}_n \right) \mathbf{Y} + \mathbf{Y}^t (\mathbf{I}_n - \mathbf{P}_X) \mathbf{Y} \quad (5.4)$$

o, equivalentemente, $SCT_{CM} = SCTra + SCE$.

La suma de cuadrados de los tratamientos corregida por la media también se puede escribir en forma matricial como:

$$SC(\bar{y}_{1.}, \dots, \bar{y}_{t.}) = \mathbf{Y}^t \mathbf{P}_a \mathbf{Y}.$$

Cada suma de cuadrados tiene asociado un número de grados de libertad, los cuales se obtienen realizando los procedimientos presentados en los capítulos 3 y 4. Al dividir cada suma de cuadrados por sus grados de libertad, se obtienen las estimaciones de varianzas (caso de efectos fijos). En el ANOVA estas varianzas se conocen como cuadrados medios.

Para este modelo se satisface que

$$E(CME) = E\left(\frac{SCE}{n-t}\right) = \sigma^2,$$

es decir, el CME es un estimador insesgado de la varianza del error, y también,

$$\begin{aligned} E(CMTra) &= \sigma^2 + \frac{1}{t-1} \sum_{i=1}^t r_i \alpha_i^2 \\ &= \sigma^2 + \frac{1}{t-1} \boldsymbol{\theta}^t \mathbf{X}^t \left(\mathbf{P}_X - \frac{1}{n} \mathbf{J}_n \right) \mathbf{X} \boldsymbol{\theta}. \end{aligned}$$

Si el efecto de α_i es cero, entonces $\sum_{i=1}^t r_i \alpha_i^2 = 0$ y el $CMTra$ también estima a σ^2 . Bajo la hipótesis nula, el cociente F es igual a la unidad, pero si algún α_i es diferente de cero, entonces $F > 1$ (el $CMTra$ es mayor al CME). Un valor de F cercano a la unidad indica que los α_i son cero o muy pequeños, lo que indica que los tratamientos pueden suponerse iguales y, por lo tanto, no se rechazaría $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_t$. Por el contrario, un valor grande de F indica que algunos α_i son diferentes de cero, por lo que existe evidencia para rechazar H_0 .

Toda la información sobre el ANOVA asociada con el modelo (5.2) se resume en las tablas 5.4 y 5.5.

Tabla 5.4: Análisis de varianza con base en el modelo (5.2)

C de V	gl	SC	E(CM)
Media	1	$Y^t \left(\frac{1}{n} J_n \right) Y = \frac{y_{..}^2}{n}$	$\sigma^2 + \theta^t X^t \frac{1}{n} J_n X \theta$
Tratam.	$t - 1$	$Y^t [P_X - \frac{1}{n} J_n] Y = \sum_{i=1}^t r_i (\bar{y}_{i.} - \bar{y}_{..})^2$	$\sigma^2 + \frac{1}{t-1} \theta^t X^t (P_X - \frac{1}{n} J_n) X \theta$
Error	$n - t$	$Y^t [I - P_X] Y = \sum_{i=1}^t \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i.})^2$	σ^2
Total	n	$Y^t Y = \sum_{i=1}^t \sum_{j=1}^{r_i} y_{ij}^2$	

Tabla 5.5: Análisis de varianza corregido por la media con base en el modelo (5.2)

C de V	gl	SC	CM	F
Tratam.	$t - 1$	$SCTra$	$CMTra = \frac{SCTra}{\frac{t-1}{n}}$	$\frac{CMTra}{CME}$
Error	$n - t$	SCE	$CME = \frac{SCE}{n - t}$	
Total	$n - 1$	SCT_{CM}		

Ejemplo 5.2. Para los datos del ejemplo 5.1, se propone el modelo $y_{ij} = \mu + D_i + e_{ij}$, con $i = 1, \dots, 4$ y $j = 1, \dots, 5$. Es de interés en esta investigación comprobar la hipótesis de igualdad del efecto medio de las dietas $H_0 : \mu_{D_1} = \mu_{D_2} = \mu_{D_3} = \mu_{D_4}$ contra H_a : al menos un par de dietas difiere en promedio. Para tal fin, con la información de la tabla 5.6, se concluye que esta hipótesis se rechaza, puesto que $F_c = 5.33 > F_{(3,16,0.05)} = 3.24$. De esta forma, se encuentran diferencias entre las medias de las dietas.

Tabla 5.6: Análisis de varianza para los datos del ejemplo 5.1 en el estudio sobre dietas

C de V	gl	SC	CM	F	Valor p
Dieta	3	165.77	55.26	5.33	0.01
Error	16	165.73	10.36		
Total	19	331.50			

Además, una estimación de la varianza del error para este conjunto de datos es $\hat{\sigma}^2 = CME = 10.36$. Esta es una varianza mancomunada del experimento y es útil para el análisis siempre que las varianzas de las dietas sean homogéneas.

Una estimación puntual de la media global del experimento es $\hat{\mu} = \bar{y}_{..} = -3.885$ kilogramos. Tiene sentido estimar esta media solo cuando no se rechaza la hipótesis nula de igualdad entre las medias de las dietas.

Los efectos de las dietas se estiman a partir de las diferencias de medias $\hat{D}_i = \bar{y}_{i.} - \bar{y}_{..}$. Estas estimaciones son:

$$\begin{aligned}
\hat{D}_1 &= \bar{y}_{1.} - \bar{y}_{..} = -2.82 + 3.885 = 1.065 \text{ kilogramos} \\
\hat{D}_2 &= \bar{y}_{2.} - \bar{y}_{..} = -7.92 + 3.885 = -4.035 \text{ kilogramos} \\
\hat{D}_3 &= \bar{y}_{3.} - \bar{y}_{..} = -0.02 + 3.885 = 3.865 \text{ kilogramos} \\
\hat{D}_4 &= \bar{y}_{4.} - \bar{y}_{..} = -4.78 + 3.885 = -0.895 \text{ kilogramos.}
\end{aligned}$$

En este caso, se observa que el valor 1.065 kilogramos para el efecto de la primera dieta significa que los individuos tratados con esta suben un kilo más que el promedio, es decir, el efecto de la primera dieta conlleva a aumentar el peso en un promedio de un kilogramo. El quinto individuo, a quien se le dio la dieta uno (D_1), subió 1.7 kilogramos. Este dato, y en forma similar para los demás, puede descomponerse según el modelo lineal como

$$\begin{aligned}
y_{15} &= \hat{\mu} + \hat{D}_1 + \hat{\epsilon}_{15} \\
1.7 &= -3.885 + 1.065 + \hat{\epsilon}_{15}.
\end{aligned}$$

Por lo tanto, $\hat{\epsilon}_{15} = 4.52$. El residuo positivo (4.52 kilogramos) provee una estimación del error aleatorio ϵ_{15} en el individuo anterior. En otras palabras, si no hubiese error aleatorio, los individuos con dieta D_1 hubiesen bajado $-3.885 + 1.065 = -2.82$ kilogramos.

5.3.1. Hipótesis asociadas

Con los resultados del ANOVA se pueden hacer estimaciones y pruebas de hipótesis. Una primera prueba de interés es la prueba F , la cual permite tomar decisiones sobre si hay diferencias entre efectos de medias de tratamientos. Este es un paso intermedio en el análisis, ya que al concluir que existen diferencias, el paso siguiente sería encontrar las medias diferentes y estimar sus diferencias. Antes de realizar estos procedimientos, es conveniente que se cumplan los supuestos del ANOVA, tema que se aborda en el siguiente capítulo.

Definición 5.1. Un contraste es una combinación lineal de los tratamientos, es decir, $\sum_{i=1}^t \lambda_i \alpha_i$, donde $\sum_{i=1}^t \lambda_i = 0$, o en forma matricial $\lambda^t \theta = 0$, con $\lambda^t = (0, \lambda_1, \dots, \lambda_t)$.

Teniendo en cuenta que $\lambda^t \theta$ es estimable, si $\lambda^t = a^t X$, entonces se obtiene

$$a^t = \left(\frac{\lambda_1}{r_1}, \dots, \frac{\lambda_1}{r_1}, \dots, \frac{\lambda_t}{r_t}, \dots, \frac{\lambda_t}{r_t} \right),$$

con a^t un vector de longitud n y los $\frac{\lambda_i}{r_i}$ de longitud r_i , $i = 1, \dots, t$. En este arreglo se satisface que $a^t X = \lambda^t$.

Observación 5.1. Se puede elegir otro $\mathbf{a}$, pero siempre se va a satisfacer que $\mathbf{P}_X \mathbf{a}$ es único.

Observación 5.2. Para un contraste $\lambda^t \boldsymbol{\theta}$, el vector $\mathbf{P}_X \mathbf{a}$ tiene la estructura matricial $\mathbf{P}_X \mathbf{a} = (p_{ij})$, con $p_{ij} = \frac{\lambda_i}{r_i}$.

Proposición 5.1. $\mathbf{a}^t \mathbf{X} \boldsymbol{\theta}$ es un contraste si y solo si $\mathbf{a}^t \mathbf{J} = \mathbf{0}$.

Proposición 5.2. $\mathbf{a}^t \mathbf{X} \boldsymbol{\theta}$ es un contraste si y solo si $\mathbf{P}_X \mathbf{a} \in \mathcal{C}(\mathbf{P}_X)$.

Sea la hipótesis lineal general

$$H_0 : \lambda^t \boldsymbol{\theta} = \mathbf{0} \quad \text{ó} \quad H_0 : \sum_{i=1}^t \lambda_i \alpha_i = 0. \quad (5.5)$$

Al desarrollar el *MELI* y la varianza de $\lambda^t \boldsymbol{\theta}$, se encuentra

$$\begin{aligned} MELI(\lambda^t \boldsymbol{\theta}) &= \lambda^t \boldsymbol{\theta}^0 = \sum_{i=1}^t \lambda_i \hat{\alpha}_i = \sum_{i=1}^t \lambda_i \bar{y}_i. \\ Var(\lambda^t \hat{\boldsymbol{\theta}}) &= \lambda^t (\mathbf{X}^t \mathbf{X})^{-1} \lambda \sigma^2 = Var \left(\sum_{i=1}^t \lambda_i \hat{\alpha}_i \right) \\ &= \sigma^2 \sum_{i=1}^t \frac{\lambda_i^2}{r_i}, \end{aligned} \quad (5.6)$$

y bajo el supuesto de normalidad de los residuales, se obtiene

$$\lambda^t \hat{\boldsymbol{\theta}} \sim N(\lambda^t \boldsymbol{\theta}, \lambda^t (\mathbf{X}^t \mathbf{X})^{-1} \lambda \sigma^2)$$

o, equivalente,

$$\sum_{i=1}^t \lambda_i \hat{\alpha}_i \sim N \left(\sum_{i=1}^t \lambda_i \alpha_i, \sigma^2 \sum_{i=1}^t \frac{\lambda_i^2}{r_i} \right).$$

El estadístico de prueba para la hipótesis (5.5) esta dado por

$$t_c = \frac{\sum_{i=1}^t \lambda_i \bar{y}_i}{\sqrt{\sum_{i=1}^t \frac{\lambda_i^2}{r_i} CME}} \sim t_{(n-t)}. \quad (5.7)$$

Con base en este estadístico se toma la decisión sobre la hipótesis nula. Al realizar la prueba a dos colas, si $|t_c| > t_{(n-t, \frac{\alpha}{2})}$, se toma la decisión de rechazar H_0 .

Un intervalo de confianza para la combinación lineal de los parámetros es

$$IC\left(\sum_{i=1}^t \lambda_i \alpha_i\right) = \sum_{i=1}^t \lambda_i \bar{y}_{i.} \mp t_{(n-t, \frac{\alpha}{2})} \sqrt{\sum_{i=1}^t \frac{\lambda_i^2}{r_i} CME}, \quad (5.8)$$

específicamente, un intervalo de confianza para la diferencia de dos dietas $\mu_i - \mu_{i'}$ es un caso particular de (5.8) y se obtiene como

$$(\bar{y}_{i.} - \bar{y}_{i'.}) \mp t_{(n-t, \frac{\alpha}{2})} \sqrt{\frac{CME}{r_i} + \frac{CME}{r_{i'}}}.$$

Ejemplo 5.3. Para los datos del ejemplo 5.1, se cree que la dieta cuatro difiere en la reducción de peso de la dieta tres. En este caso, se desea contrastar $H_0 : \mu_3 = \mu_4$ contra $H_a : \mu_3 \neq \mu_4$. Haciendo uso del estadístico (5.7), se encuentra que

$$t_c = \frac{-0.02 + 4.78}{\sqrt{\frac{2}{5}(10.36)}} = 2.34.$$

Como $t_c = 2.34 > t_{(16, 0.05)} = 1.746$, entonces se rechaza la hipótesis de igualdad entre las dietas tres y cuatro al 10 % de significación, corroborando la diferencia entre dietas.

El intervalo de confianza del 90 % a dos colas se obtiene solamente con el fin de ilustrar el procedimiento, es decir

$$\begin{aligned} & (-0.02 + 4.78) \pm t_{(16, 0.05)} \sqrt{\frac{2}{5}(10.36)} \\ & 4.76 \pm (1.75)(2.04) \\ & 1.19 < \mu_3 - \mu_4 < 8.33. \end{aligned}$$

La dieta D_3 es menos efectiva que la dieta D_4 (menor disminución de peso) y la diferencia está entre 1.19 y 8.33 kilogramos. Este intervalo no contiene el cero, lo que permite concluir que las dietas D_3 y D_4 tienen promedios diferentes. Es de anotar que este procedimiento no debería seguirse para comparar todas las medias por pares. Las seis comparaciones serían conjuntamente dependientes y, por lo tanto, los resultados no serían válidos estadísticamente. El procedimiento de comparaciones por pares merece un análisis más detallado, este se hace en el capítulo 6.

5.4. DCA a través del modelo de medias de celda

La estructura matricial del modelo (5.1) es

$$Y = W\mu + \epsilon, \quad (5.9)$$

donde

$$\mathbf{W} = \text{Diag}(\mathbf{1}_{r_i}) = \bigoplus_{i=1}^t \mathbf{1}_{r_i},$$

con $\bigoplus$ la suma directa de matrices y

$$\mathbf{1}_{r_i} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}_{r_i \times 1}$$

Bajo el supuesto que $\boldsymbol{\epsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$, se encuentra de (5.9) que

$$E(\mathbf{Y}) = \mathbf{W} \boldsymbol{\mu} = \begin{bmatrix} \mu_{11} \\ \vdots \\ \mu_{1r_1} \\ \vdots \\ \mu_{2r_2} \\ \vdots \\ \mu_{tr_t} \end{bmatrix}, \quad \text{Var}(\mathbf{Y}) = \sigma^2 \mathbf{I} \quad \text{y} \quad (\mathbf{W}^t \mathbf{W}) = \text{Diag}(r_i) = \bigoplus_{i=1}^t r_i.$$

Entonces, el sistema de ecuaciones normales $\mathbf{W}^t \mathbf{W} \boldsymbol{\mu} = \mathbf{W}^t \mathbf{Y}$ es de la forma

$$\text{Diag}(r_i) \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_t \end{bmatrix} = \begin{bmatrix} y_{1.} \\ \vdots \\ y_{t.} \end{bmatrix}.$$

Una ventaja del uso de modelos de medias es que el sistema tiene solución única, dada por

$$\hat{\boldsymbol{\mu}} = (\mathbf{W}^t \mathbf{W})^{-1} \mathbf{W}^t \mathbf{Y} = \begin{bmatrix} \bar{y}_{1.} \\ \vdots \\ \bar{y}_{t.} \end{bmatrix}.$$

De esta forma, $MELI(\hat{\mu}_i) = \bar{y}_{i.}$. En general, $MELI(\mathbf{k}^t \boldsymbol{\mu}) = \mathbf{k}^t \hat{\boldsymbol{\mu}}$. Nótese, sin pérdida de generalidad, que

$$\mathbf{k}_i^t \boldsymbol{\mu} = (0 \ \dots \ 0 \ 1 \ 0 \ \dots \ 0) \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_i \\ \vdots \\ \mu_t \end{bmatrix} = \mu_i$$

y, entonces,

$$\mathbf{k}_i^t \hat{\boldsymbol{\mu}} = (0 \ \dots \ 0 \ 1 \ 0 \ \dots \ 0) \begin{bmatrix} \bar{y}_{1.} \\ \vdots \\ \bar{y}_{i.} \\ \vdots \\ \bar{y}_{t.} \end{bmatrix} = \bar{y}_{i.}$$

De esta forma, su varianza es

$$\begin{aligned} Var(\mathbf{k}_i^t \hat{\boldsymbol{\mu}}) &= \mathbf{k}_i^t (\mathbf{W}^t \mathbf{W})^{-1} \mathbf{k}_i \sigma^2 = Var(\bar{y}_{i.}) \\ &= (0 \ \dots \ 0 \ 1 \ 0 \ \dots \ 0) \begin{bmatrix} \frac{1}{r_1} & \dots & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \dots & \frac{1}{r_i} & \vdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & \dots & \frac{1}{r_t} \end{bmatrix} \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \sigma^2 \\ &= \frac{\sigma^2}{r_i}. \end{aligned}$$

Además, se satisface que $E(\hat{\mu}_i) = E(\bar{y}_{i.}) = \mathbf{k}_i^t \boldsymbol{\mu} = \mu_i$, $\hat{\mu}_i \sim N(\mu_i, \sigma^2/r_i)$ y

$$\begin{aligned} Cov(\hat{\mu}_i, \hat{\mu}_{i'}) &= Cov(\mathbf{k}_i^t \hat{\boldsymbol{\mu}}, \mathbf{k}_{i'}^t \hat{\boldsymbol{\mu}}) = \mathbf{k}_i^t Cov(\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\mu}}) \mathbf{k}_{i'} \\ &= \mathbf{k}_i^t (\mathbf{W}^t \mathbf{W})^{-1} \mathbf{k}_{i'} \sigma^2, \quad i \neq i' \end{aligned}$$

Al asumir normalidad e independencia, se sigue que

$$Var\left(\sum_{i=1}^t c_i \hat{\mu}_i\right) = \sigma^2 \sum_{i=1}^t \frac{c_i^2}{r_i}.$$

Si se satisface que $\sum_{i=1}^t c_i = 0$, entonces se tiene un contraste lineal.

5.4.1. Reducción de la suma de cuadrados

Es conocido, por los resultados obtenidos en la sección 3.2.1.2, que

$$\|\mathbf{Y}\|^2 = \|\hat{\mathbf{Y}}\|^2 + \|\hat{\boldsymbol{\epsilon}}\|^2,$$

donde

$$\begin{aligned} SCM &= \|\hat{\mathbf{Y}}\|^2 = \hat{\mathbf{Y}}^t \hat{\mathbf{Y}} = \sum_{ij} \hat{y}_{ij}^2 = \mathbf{Y}^t \mathbf{W} \hat{\boldsymbol{\mu}} \\ &= \mathbf{Y}^t \mathbf{W} \begin{bmatrix} \hat{\mu}_1 \\ \vdots \\ \hat{\mu}_t \end{bmatrix} = \hat{\boldsymbol{\mu}}^t \mathbf{W}^t \mathbf{Y} = (\bar{y}_{1.}, \dots, \bar{y}_{t.}) \begin{bmatrix} y_{1.} \\ \vdots \\ y_{t.} \end{bmatrix} = \sum_{i=1}^t \bar{y}_i y_{i.}. \end{aligned}$$

Como $y_{i.} = r_i \bar{y}_{i.}$, entonces se obtiene

$$SCM = \sum_{i=1}^t r_i \bar{y}_{i.}^2 = \sum_{i=1}^t \frac{y_{i.}^2}{r_i} = \mathbf{Y}^t \mathbf{P}_W \mathbf{Y} = R(\mu_i).$$

En este caso,

$$\mathbf{P}_W = \frac{1}{r_1} \mathbf{J}_{r_1} \bigoplus \frac{1}{r_2} \mathbf{J}_{r_2} \bigoplus \dots \bigoplus \frac{1}{r_t} \mathbf{J}_{r_t},$$

y la suma de cuadrados del residual está dada por

$$\begin{aligned} SCE &= \|\hat{\boldsymbol{\epsilon}}\|^2 = \|\mathbf{Y} - \mathbf{W} \hat{\boldsymbol{\mu}}\|^2 \\ &= \mathbf{Y}^t (\mathbf{I} - \mathbf{P}_W) \mathbf{Y} = \sum_{ij} (y_{ij} - \hat{y}_{ij})^2 \\ &= \sum_{ij} \hat{\epsilon}_{ij}^2 = \sum_{ij} (y_{ij} - \bar{y}_{i.})^2. \end{aligned}$$

Si se ajusta el modelo (5.1), se sigue que

$$\hat{\mu} = \frac{y_{..}}{n} = \bar{y}_{..} \quad \text{y} \quad SC(\mu) = R(\mu) = n \left(\frac{\sum_{ij} y_{ij}}{n} \right)^2 = n \bar{y}_{..}^2$$

Al definir la reducción de la suma de cuadrados total debido a las medias ajustadas por la media general como

$$\begin{aligned} SCTra &= R(\mu_i | \mu) = R(\mu_i) - R(\mu) \\ &= \sum_{i=1}^t r_i \bar{y}_{i.}^2 - n \bar{y}_{..}^2 \\ &= \sum_{i=1}^t r_i (\bar{y}_{i.} - \bar{y}_{..})^2, \end{aligned}$$

se encuentra que este resultado es igual a la suma de cuadrados de tratamientos en el modelo superparametrizado, es decir,

$$\begin{aligned} SCT_{CM} &= SC(\mu_i) + SCE \\ &= R(\mu_i|\mu) + R(\mu) + SCE \\ &= SCTra + SCE, \end{aligned}$$

donde $SCT_{CM} = SCT_{total} - R(\mu)$. Los resultados anteriores se resumen en tabla 5.7 de análisis de varianza. En esta se observa que el análisis de varianza para los modelos (5.1) y (5.2) coinciden.

Tabla 5.7: Análisis de varianza para el modelo (5.1)

C de V	gl	SC	E(CM)
Media	1	$R(\mu) = n\bar{y}_{..}^2$	$\sigma^2 + \mu^t \mathbf{W}^t \frac{1}{n} \mathbf{J}_n \mathbf{W} \mu$
Tratam.	$t - 1$	$R(\mu_i) - R(\mu) = \sum_{i=1}^t r_i (\bar{y}_{i.} - \bar{y}_{..})^2$	$\sigma^2 + \frac{1}{t-1} \mu^t \mathbf{W}^t (\mathbf{P}_W - \frac{1}{n} \mathbf{J}_n) \mathbf{W} \mu$
Error	$n - t$	$\mathbf{Y}^t [\mathbf{I} - \mathbf{P}_W] \mathbf{Y} = \sum_{i=1}^t \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i.})^2$	σ^2
Total	n	$\mathbf{Y}^t \mathbf{Y} = \sum_{i=1}^t \sum_{j=1}^{r_i} y_{ij}^2$	

5.4.2. Hipótesis asociadas

Sea la hipótesis lineal general

$$H_0 : \pi^t \mu = m \quad \text{o} \quad H_0 : \sum_{i=1}^t c_i \mu_i = m$$

Al imponerse una restricción estimable sobre los parámetros del modelo, como la planteada en la hipótesis anterior, se tiene que la suma de cuadrados del residuo se incrementa en δ a través de la estimación máximo verosímil, o sea,

$$SCE_{H_0} = SCE + \delta,$$

donde

$$\delta = (\pi^t \hat{\mu} - m)^t [\pi^t (\mathbf{W}^t \mathbf{W})^{-1} \pi]^{-1} (\pi^t \hat{\mu} - m).$$

En este caso,

$$MELI \left(\sum_{i=1}^t c_i \mu_i \right) = \sum_{i=1}^t c_i \hat{\mu}_i = \sum_{i=1}^t c_i \bar{y}_{i.},$$

y como

$$\pi^t (\mathbf{W}^t \mathbf{W})^{-1} \pi = \sum_{i=1}^t \frac{c_i^2}{r_i},$$

de esta forma,

$$\delta = \left(\sum_{i=1}^t c_i \bar{y}_{i.} - m \right) \left(\sum_{i=1}^t \frac{c_i^2}{r_i} \right)^{-1} \left(\sum_{i=1}^t c_i \bar{y}_{i.} - m \right) = \frac{\left(\sum_{i=1}^t c_i \bar{y}_{i.} - m \right)^2}{\sum_{i=1}^t \frac{c_i^2}{r_i}}.$$

Se observa que si $m = 0$, entonces

$$\delta = \frac{\left(\sum_{i=1}^t c_i \bar{y}_{i.} \right)^2}{\sum_{i=1}^t \frac{c_i^2}{r_i}}.$$

Cuando la hipótesis nula es cierta, entonces $\delta = 0$. Además, el *MELI* y la varianza del *MELI* de la combinación lineal $\boldsymbol{\pi}^t \boldsymbol{\mu}$ son respectivamente

$$MELI(\boldsymbol{\pi}^t \boldsymbol{\mu}) = \boldsymbol{\pi}^t \hat{\boldsymbol{\mu}} = \sum_{i=1}^t c_i \bar{y}_{i.}$$

$$Var(\boldsymbol{\pi}^t \hat{\boldsymbol{\mu}}) = \boldsymbol{\pi}^t (\mathbf{W}^t \mathbf{W})^{-1} \boldsymbol{\pi} \sigma^2 = Var \left(\sum_{i=1}^t c_i \hat{\mu}_i \right) = \sigma^2 \sum_{i=1}^t \frac{c_i^2}{r_i};$$

y bajo el supuesto de normalidad de las observaciones, se obtiene

$$\boldsymbol{\pi}^t \hat{\boldsymbol{\mu}} \sim N(\boldsymbol{\pi}^t \boldsymbol{\mu}, \boldsymbol{\pi}^t (\mathbf{W}^t \mathbf{W})^{-1} \boldsymbol{\pi} \sigma^2)$$

ó, equivalente,

$$\sum_{i=1}^t c_i \hat{\mu}_i \sim N \left(\sum_{i=1}^t c_i \mu_i, \sigma^2 \sum_{i=1}^t \frac{c_i^2}{r_i} \right).$$

Un intervalo de confianza del $(1 - \alpha) \%$ para la combinación lineal de los parámetros es

$$IC \left(\sum_{i=1}^t c_i \mu_i \right) = \sum_{i=1}^t c_i \bar{y}_{i.} \pm t_t \sqrt{\sum_{i=1}^t \frac{c_i^2}{r_i} CME},$$

con $t_t = t_{(n-t, \alpha/2)}$.

Ejemplo 5.4. Para los datos del ejemplo 5.1, si se desean responder las mismas inquietudes planteadas en el ejemplo 5.3, se encuentra un resultado similar en cuanto a la hipótesis de igualdad entre efectos medios de las dietas tres y cuatro, ya que se utiliza el mismo estadístico para decidir al respecto. Igualmente sucede con el intervalo de confianza.

5.5. Modelo de componentes de varianza

La selección de los tratamientos o niveles del factor determinan el procedimiento que debe usarse en el análisis. El modelo I es apropiado cuando los tratamientos son fijos o el experimentador los elige debido a su importancia, disponibilidad o comodidad en el manejo. En este modelo los parámetros son generalmente las medias de los tratamientos y el objetivo es la comparación y estimación de estos promedios. En el modelo II, los niveles del factor pertenecen a una población de la cual se toma una muestra aleatoria, por ejemplo, animales de una especie dada, hojas de una planta, sitios de un lago, personas sanas con otra característica definida. Cada individuo seleccionado en la muestra origina una o varias lecturas de la variable respuesta ya sea en días diferentes o en otra situación que permita determinar la variabilidad de la característica en el mismo individuo. Los parámetros de interés en este modelo son las varianzas y el objetivo primordial es estimar sus magnitudes absolutas y relativas (Searle, Casella y McCulloch 1987). El ANOVA, en este modelo, permite inferir sobre la existencia de una componente de varianza atribuible al factor en estudio y, en este sentido, se tiene lo que sería el verdadero análisis de varianza.

El modelo estadístico para un DCA (un factor y efectos aleatorios) tiene la forma

$$y_{ij} = \mu + A_i + \epsilon_{ij}, \quad i = 1, 2, \dots, t, \quad j = 1, 2, \dots, r_i. \quad (5.10)$$

La diferencia con respecto al modelo de efectos fijos está en el segundo término, en este modelo los efectos A_i son variables aleatorias, mientras que en el modelo I los efectos α_i son parámetros. Para analizar este diseño, es necesario imponer las siguientes restricciones:

- i. Los efectos A_i son variables aleatorias independientes con distribución normal $N(0, \sigma_A^2)$.
- ii. Los errores ϵ_{ij} son variables aleatorias independientes con distribución normal $N(0, \sigma_\epsilon^2)$.
- iii. A_i y ϵ_{ij} son variables aleatorias independientes entre sí.

La tabla ANOVA es la misma para ambos modelos (de efectos fijos y aleatorios), tanto los cálculos de las sumas de cuadrados como la prueba F de significación son igualmente válidos para el modelo II.

Las hipótesis del ANOVA para el modelo II se plantean como:

$H_0 : \sigma_A^2 = 0$ (no hay variabilidad entre los niveles del factor A).

$H_1 : \sigma_A^2 > 0$ (la variabilidad entre los niveles es significativa).

En la tabla 5.8, se presenta el análisis de varianza asociada con el modelo lineal propuesto en (5.10).

Tabla 5.8: ANOVA a una vía para efectos aleatorios

C de V	gl	SC	CM	E(CM)	F
Factor A	$t - 1$	SCA	CMA	$\sigma_\epsilon^2 + r_0 \sigma_A^2$	$\frac{CMA}{CME}$
Error	$n - t$	SCE	CME	σ_ϵ^2	
Total	$n - 1$	SCT			

con $r_0 = \frac{n - \sum_{i=1}^t \frac{r_i^2}{n}}{t-1}$ y $n = \sum r_i$.

Si $F > F_{(v_1, v_2, \alpha)}$, se rechaza H_0 . La regla de decisión es la misma del modelo I, pero la interpretación es diferente. Los datos del modelo II provienen de un diseño distinto, el objetivo es estimar varianzas y no medias. Además, el espacio inferencial es más amplio para el modelo II. Se debe tener claridad que aunque el ANOVA sea el mismo, las conclusiones son diferentes, puesto que los diseños experimentales cumplen objetivos en esencia diferentes.

Los estimadores del análisis de varianza para determinar las componentes σ_ϵ^2 y σ_A^2 son

$$\hat{\sigma}_\epsilon^2 = CME$$

y

$$\hat{\sigma}_A^2 = \frac{CMA - CME}{r_0}.$$

Si los supuestos del modelo II se satisfacen (ver capítulo 6), la varianza de cada observación y_{ij} puede expresarse mediante dos componentes dadas por los términos de la suma $\sigma_y^2 = \sigma_A^2 + \sigma_\epsilon^2$.

Ejemplo 5.5. *Un estudio genético en ganado consistió en seleccionar aleatoriamente varios machos (toros) apareados con grupos separados de hembras. Cuando nacieron los terneros, se midieron los pesos iniciales como medida en un estudio de pesos hereditarios (estudios de progene). En la tabla 5.9, se presentan los pesos al nacer de los terneros de cada uno de cinco grupos de apareamiento.*

Como los cinco toros fueron seleccionados aleatoriamente de un número grande de posibles padres, esto conlleva a un estudio de efectos aleatorios, siendo la hipótesis de interés

$H_0 : \sigma_A^2 = 0$ (no hay variabilidad entre padres).

$H_a : \sigma_A^2 > 0$ (la variabilidad entre padres es significativa).

Tabla 5.9: Pesos de los terneros al nacer en una evaluación genética

Replicación	Número del macho elegido				
	85	113	134	158	165
1	61	75	58	57	59
2	71	102	60	121	46
3	56	95	59	56	120
4	75	103	65	58	115
5	99	98	54	101	93
6	80	115	57	110	105
7	75			67	75
8	62				115

En esta investigación no se consideran los promedios por padre (cada toro es un tratamiento), puesto que los cinco toros del experimento no son los únicos que interesan; el objetivo se centra en la variabilidad poblacional de los padres. El factor de estudio es la paternidad (influencia hereditaria) que se expresa en el peso de los terneros hijos. Aquí cada ternero es una unidad experimental, pero en otros estudios cada animal podría generar varias unidades experimentales correspondientes a lecturas o mediciones en tiempos diferentes. El animal, para este ejemplo, es el toro, el cual produce las unidades experimentales que son los terneros hijos.

La tabla de ANOVA se construye igual que en el modelo I, los resultados se presentan en la tabla 5.10.

Tabla 5.10: ANOVA para los datos del ejemplo 5.5

Causa de variación	gl	SC	CM	F	Valor P
Entre toros	4	6070.32	1517.58	3.65	0.02
Error	30	12486.42	416.21		
Total	34	18556.74			

El valor tabulado $F_{(4,30,0.05)} = 2.69$ es menor que el cociente $F = 3.65$ de la tabla 5.10, lo que permite concluir que la variabilidad entre padres es significativa estadísticamente. A partir de este resultado, es interesante conocer qué parte de la variabilidad en las unidades experimentales es asignable a los padres (σ_A^2) y qué parte es atribuible al error experimental (σ_ϵ^2). Es obvio que no tendría sentido diferenciar estas variabilidades si la conclusión del ANOVA hubiese dado a favor de la hipótesis nula.

En el modelo se tienen tres parámetros (μ , σ_A^2 , σ_ϵ^2). La estimación de las componentes de varianza se obtiene a partir de las medias cuadráticas, así,

$$\hat{\sigma}_\epsilon^2 = CME = 416.21$$

y

$$\hat{\sigma}_\epsilon^2 + r_0 \hat{\sigma}_A^2 = CMA,$$

donde

$$r_0 = \frac{35 - \frac{(8^2+6^2+6^2+7^2+8^2)}{35}}{4} = 6.97.$$

Luego,

$$\hat{\sigma}_A^2 = \frac{(CMA - CME)}{r_0} = \frac{(1517.58 - 416.21)}{6.97} = 158.02$$

$$\hat{\sigma}_y^2 = 416.21 + 158.02 = 574.23.$$

Normalmente, estas estimaciones no dan una información fácilmente interpretable. Por esto, lo usual es expresar los resultados como porcentajes de la variación total. En este caso, se considera el cociente

$$r_I = \frac{\hat{\sigma}_A^2}{\hat{\sigma}_y^2} = \frac{158.02}{574.23} = 0.2752,$$

que mide la proporción de la variabilidad total que es atribuible al factor, en este caso, los padres. En porcentaje, esta variabilidad es el 27.52%; el otro 72.48 % hace referencia a la variabilidad entre terneros del mismo padre.

El cociente r_I se conoce como coeficiente de correlación intraclase y es una medida de la semejanza de los individuos dentro de un mismo grupo. Este coeficiente varía entre 0 y 1. Entre más grande sea su valor, mayor es la similitud entre los elementos de cada grupo. Lo significativo de la correlación intraclase está ligado directamente a la prueba F del ANOVA. En efecto, si se rechaza H_0 , se concluye que la variabilidad debida a padres es alta y que la variabilidad restante debida a otras causas, como el ambiente, es baja, lo que lleva a la similitud entre las observaciones por grupo.

Tiene sentido hablar de la correlación intraclase porque en el modelo II, a diferencia del modelo I, las observaciones y_{ij} en un mismo grupo pueden ser estadísticamente dependientes.

Otra diferencia del modelo de componentes de varianza con respecto al modelo de efectos fijos se da en el valor esperado μ que es igual para todas las observaciones. Esta media μ se estima puntualmente mediante $\bar{y}_{..} = \frac{2818}{35} = 80.51$ Kg y por intervalos con la expresión $\bar{y}_{..} \mp t_{(t-1, \frac{\alpha}{2})} \sqrt{\frac{CMA}{n}}$.

Para una confiabilidad del 95 %, este intervalo es:

$$80.51 \mp 2.78 \sqrt{\frac{1517.58}{35}},$$

es decir, $(80.51 \mp 18.31) = (62.20, 98.82)$ Kg.

Para los genetistas tiene importancia el concepto de heredabilidad. El índice de heredabilidad se estima mediante la expresión $\hat{h}^2 = 4r_I$, es una

medida del grado de influencia genética que puede recibir un genotipo. Para el ejemplo, la estimación del coeficiente de heredabilidad fue de 1.10, un valor demasiado alto, pero explicable por la gran variabilidad de $\hat{\sigma}_A^2$.

La distribución de $\hat{\sigma}_A^2$ es sesgada y muy variable. Esto hace que los intervalos de confianza para σ_A^2 sean aproximados. Estos intervalos se han derivado para el caso de grupos iguales, pero pueden extenderse, agregando otra aproximación, a grupos desiguales usando r_0 en vez de r . Uno de los intervalos propuestos por Moriguti (1954), citado por Gill (1978), tiene los siguientes límites:

$$\begin{aligned}\text{Límite inferior} &= \frac{CME}{r_0} \left[\frac{F}{F_\infty} - 1 + \frac{F_v}{F} \left(1 - \frac{F_v}{F_\infty} \right) \right] \\ \text{Límite superior} &= \frac{CME}{r_0} \left[FF'_\infty - 1 + \frac{1}{FF'_v} \left(1 - \frac{F'_\infty}{F'_v} \right) \right],\end{aligned}$$

donde $F_v = F_{(v_1, v_2, \frac{\alpha}{2})}$, $F'_v = F_{(v_2, v_1, \frac{\alpha}{2})}$, $F = \frac{CMA}{CME}$, $F_\infty = F_{(v_1, \infty, \frac{\alpha}{2})}$ y $F'_\infty = F_{(\infty, v_1, \frac{\alpha}{2})}$ con $v_1 = t - 1$ y $v_2 = n - t$.

Algunas estimaciones de σ_A^2 pueden resultar negativas (cuando $CMA < CME$, por ejemplo). Esto puede atribuirse, según Gill (1978), a la variación muestral de las medias cuadráticas, la falta de aleatorización entre tratamientos y la correlación negativa de los errores experimentales dentro de algún grupo. En el caso de obtener una estimación de componente de varianza negativo, se debe reajustar el modelo removiendo el coeficiente asociado con la estimación negativa (Brown y Prescott 1999).

Un intervalo de confianza para el coeficiente poblacional de correlación intraclass ρ_I se obtiene a partir de la expresión

$$\frac{I}{I+1} \leq \rho_I \leq \frac{S}{S+1},$$

donde $I = \frac{1}{t} \left(\frac{F}{F_{(v_1, v_2, \frac{\alpha}{2})}} - 1 \right)$ y $S = \frac{1}{t} \left(\frac{F}{F_{(v_1, v_2, 1-\frac{\alpha}{2})}} - 1 \right)$.

Ejemplo 5.6. Retomando los datos del ejemplo 5.5, un intervalo de confianza del 95% para σ_A^2 es

$$\begin{aligned}LIC &= 59.71 \left[\frac{3.65}{2.79} - 1 + \frac{3.25}{3.65} \left(1 - \frac{3.25}{2.79} \right) \right] \\ &= 9.64 \\ LSC &= 59.71 \left[(3.65)(8.26) - 1 + \frac{1}{(3.65)(8.46)} \left(1 - \frac{8.26}{8.46} \right) \right] \\ &= 1740.53.\end{aligned}$$

El intervalo es $9.64 \leq \sigma_A^2 \leq 1740.53$ que resulta demasiado amplio si se observa que el límite superior es casi 11 veces la estimación puntual de 158.02 obtenida anteriormente. Una de las razones que explica la poca precisión en la estimación de σ_A^2 es el tamaño tan reducido de la muestra analizada.

Para la correlación intraclase, con $\alpha = 0.05$, $v_1 = 4$, $v_2 = 30$, se tiene $F_{(4,30,0.025)} = 3.25$ y $F_{(4,30,0.975)} = 0.118$. Luego, $I = \frac{1}{5} \left(\frac{3.65}{3.25} - 1 \right) = 0.025$ y $S = \frac{1}{5} \left(\frac{3.65}{0.118} - 1 \right) = 5.98$.

Finalmente, el intervalo de confianza es $0.024 \leq \rho_I \leq 0.857$. Se observa la imprecisión de este intervalo, explicable por su dependencia de las componentes de varianzas muestrales.

5.6. Análisis de un DCA a través de pruebas de localización no paramétricas

Se trata ahora de extender el problema de localización estudiado en el capítulo 2 para una y dos muestras al caso de t muestras independientes.

Se trabaja bajo una estructura de diseño a una vía de clasificación para este tipo de datos. Mediante las t muestras, se quiere verificar la hipótesis que los datos provienen de una misma población (la media no difiere significativamente).

Una situación experimental, para este caso, es aquella donde las t muestras aleatorias han sido obtenidas desde t poblaciones, posiblemente diferentes. Se quiere verificar la hipótesis todas las poblaciones son idénticas respecto a la alternativa algunas poblaciones tienden a poseer valores más grandes (o pequeños) que otras.

En esta sección, se presta especial atención a la prueba de *Kruskal-Wallis*, junto con una prueba de comparaciones múltiples, para ayudar a identificar las poblaciones que tienen características diferentes.

5.6.1. Prueba de Kruskal-Wallis

Kruskal y Wallis (1952) presentan una prueba para arreglos a una vía de clasificación. En la construcción de la prueba, se tiene el diseño en t muestras:

$$y_{11}, y_{12}, \dots, y_{1r_1}, y_{21}, y_{22}, \dots, y_{2r_2}, \dots, y_{t1}, y_{t2}, \dots, y_{tr_t}$$

de poblaciones $F(y, \theta_1), F(y, \theta_2), \dots, F(y, \theta_t)$, respectivamente. Un arreglo de los datos se presentó en la tabla 5.3.

El interés se centra en construir una prueba para la hipótesis

$$H_0 : \theta_1 = \theta_2 = \cdots = \theta_t$$

respecto a

$$H_a : \text{al menos } \theta_i \neq \theta_{i'}, \quad i \neq i', \quad i, i' = 1, \dots, t.$$

Las técnicas no paramétricas desarrolladas para el problema de t -muestras no requieren otro supuesto más que el de continuidad. La estrategia básica de la prueba de Kruskal-Wallis es asignar rangos a las n observaciones y comparar la suma de los rangos por muestra (columna o tratamiento). Sea R_{ij} el rango de y_{ij} , los cuales se presentan en la tabla 5.11, donde

$$R_{i.} = \sum_{j=1}^{r_i} R_{ij} \quad \text{y} \quad \bar{R}_{i.} = \frac{R_{i.}}{r_i}, \quad i = 1, \dots, t.$$

Tabla 5.11: Rangos asociados con el esquema de datos de la tabla 5.3 para un modelo a una vía de clasificación

Niveles del factor A (tratamientos)							
Réplicas	1	2	...	i	...	t	
1	R_{11}	R_{21}	...	R_{i1}	...	R_{t1}	
2	R_{12}	R_{22}	...	R_{i2}	...	R_{t2}	
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$	
j	R_{1j}	R_{2j}	...	R_{ij}	...	R_{tj}	
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$	
r_i	R_{1r_i}	R_{2r_i}	...	R_{ir_i}	...	R_{tr_i}	
Total	$R_{1.}$	$R_{2.}$	...	$R_{i.}$	...	$R_{t.}$	$R_{..}$
Observ.	r_1	r_2	...	r_i	...	r_t	n

La estadística de *Kruskal-Wallis* se calcula a partir de la expresión:

$$H = \frac{12}{n(n+1)} \sum_{i=1}^t \frac{1}{r_i} \left[R_{i.} - \frac{r_i(n+1)}{2} \right]^2. \quad (5.11)$$

Bajo la hipótesis de que las muestras provienen de la misma población, H tiene una distribución asintótica *ji-cuadrado* con $(t-1)$ grados de libertad.

La siguiente expresión es equivalente algebraicamente a la obtenida en (5.11)

$$H = \frac{12}{n(n+1)} \sum_{i=1}^t \frac{R_{i.}^2}{r_i} - 3(n+1), \quad (5.12)$$

se rechaza $H_0 : \theta_1 = \theta_2 = \dots = \theta_k$ con un nivel de significación aproximado de α cuando $H \geq \chi^2_{(t-1, \alpha)}$, donde $\chi^2_{(t-1, \alpha)}$ es el percentil $(1 - \alpha)$ de la distribución ji-cuadrado con $t - 1$ grados de libertad.

El supuesto inicial de población continua, obvio al menos teóricamente, el problema de empates. Por problemas propios de la muestra se pueden presentar empates. Esta situación se resuelve con el método del rango promedio explicado en el capítulo 2. En caso de empates, se sigue el mismo procedimiento de la prueba de Mann-Whitney, que emplea la siguiente estadística para empates

$$H^* = \frac{H}{1 - \sum_{i=1}^l \frac{\xi_i(\xi_i^2 - 1)}{n(n^2 - 1)}}, \quad (5.13)$$

con l el número total de empates y ξ_i el número de observaciones empatadas en el i -ésimo empate, más detalles se pueden ver en Corzo (2005).

Ejemplo 5.7. *En un estudio experimental, se quieren comparar tres dietas con un contenido de colesterol diferente, con el fin de medir la tensión arterial sistólica (TAS) en personas de edad avanzada. Se consideraron 5 personas con la dieta tipo A, 4 con la tipo B y 4 con la C. En la tabla 5.12, se presentan los datos junto con sus respectivos rangos (en paréntesis).*

Tabla 5.12: Datos sobre tensión arterial sistólica y rangos asociados

Dieta			
A	B	C	
172 (9.5)	175 (11)	160 (4.5)	
169 (8.0)	164 (7.0)	160 (4.5)	
180 (13.0)	150 (2.5)	150 (2.5)	
172 (9.5)	161 (6.0)	148 (1.0)	
178 (12.0)			
$R_{1.} = 52.0$	$R_{2.} = 26.5$	$R_{3.} = 12.5$	$R_{..} = 91$

En este caso $n = 5 + 4 + 4 = 13$, haciendo uso de (5.11) se tiene que el valor de H es

$$H = \frac{12}{(13)(14)} \left[\frac{52.0^2}{5} + \frac{26.5^2}{4} + \frac{12.5^2}{4} \right] - 3(14) = 7.81.$$

De la tabla A.7 del apéndice, para $r_1 = 5$, $r_2 = r_3 = 4$, $P(H \geq 5.62) = 0.05$, como 7.81 es un valor más extremo su valor- p será menor que 0.05, es decir, $\alpha^* = P(H \geq 7.81) = 0.02 < 0.05$. Entonces se rechaza la hipótesis de igualdad de las tres dietas.

Como el valor de $\chi^2_{(2,0.05)} = 5.99$ es menor que 7.81, se rechaza también la hipótesis de que los TAS promedio son iguales para las tres dietas.

En la tabla 5.12, hay un problema de empates. Esto lleva al cálculo de la estadística H^* . En este caso, hay tres empates (150, 160 y 172), luego $l = 3$. Los tres tienen de a dos empates, luego $\xi_1 = \xi_2 = \xi_3 = 2$, y, por (5.13),

$$H^* = \frac{7.81}{1 - \frac{2(4-1)+2(4-1)+2(4-1)}{(13)(168)}} = 7.87.$$

El resultado encontrado para H^* no cambia “sustancialmente” la decisión anterior.

Para efectos de cálculo, con el procedimiento NPAR1WAY del paquete SAS se puede desarrollar el análisis de varianza que conlleva al cálculo de la estadística de Kruskal-Wallis. Otra alternativa consiste en asignar rangos a las observaciones mediante el procedimiento RANK del SAS y, luego, desarrollar un análisis de varianza corriente mediante el procedimiento ANOVA (o el GLM) del mismo paquete SAS.

5.7. Número de réplicas en un diseño completamente aleatorizado

Según Fisher, para tener una estimación válida del error experimental (EE) se requieren como condiciones básicas la replicación y la aleatorización. La necesidad de replicar en experimentación fue reconocida por investigadores experimentales desde 1864, aclarando que si los tratamientos son aplicados a un material experimental absolutamente homogéneo, entonces una única réplica es suficiente para sacar conclusiones acerca de la población.

El número de observaciones para un experimento es determinado por:

- El grado de precisión deseado.
- La cantidad de variabilidad presente en el material experimental.
- Los recursos disponibles, incluyendo personal y equipo (costo del experimento).
- El tamaño y forma de la unidad experimental (especialmente en experimentos agrícolas).

Observación 5.3. El grado de precisión deseado depende de la naturaleza de los tratamientos y las características observadas, así como la magnitud

esperada de la diferencia media de efectos de tratamientos para un carácter (variable) específico. Si las diferencias son grandes, un grado de precisión bajo puede ser aceptado. Este se define como la variabilidad asociada con las medias de los tratamientos (varianza de las medias de los tratamientos).

Como siempre se va a tener una diferencia específica entre los tratamientos, el experimentador toma la decisión con respecto al riesgo de forma arbitraria:

- i. Asegurando que ciertas diferencias de determinado tamaño no existen cuando ellas realmente están presentes (error tipo II).
- ii. Asegurando que grandes diferencias son encontradas, cuando estas diferencias no son ciertas (error tipo I).

El grado de precisión deseado puede ser expresado en porcentaje de la media. En conexión con el número de réplicas, el experimentador puede listar las características de interés con la desviación estándar estimada. El número de réplicas es determinado por la variabilidad de la característica de interés, en tanto, si varias características son importantes, el número de réplicas es determinado por la característica más variable.

Cuando el tamaño de la diferencia de tratamientos está basado en múltiples variables y se desea diferentes niveles de confianza para el conjunto de características, se hace necesario calcular el número de réplicas requeridas para todas las características individualmente y escoger el de mayor número para las condiciones especificadas en el experimento.

El grado de variabilidad presente en el modelo experimental depende de los tratamientos ensayados y de las características a medir. Algunas características tienen mayor grado de variabilidad relativa que otras. El coeficiente de variación (CV) debe ser usado como medida para observar estas características, pero no usado para comparar la variación relativa de estas.

Si se desea calcular el número de réplicas requerido para detectar una diferencia mínima específica, se considera la diferencia media de dos tratamientos con un nivel específico de significación α .

Varios métodos están disponibles en la literatura para obtener este número de réplicas. Cuando se hace uso del bien conocido estadístico t , el número de réplicas es obtenido a partir de la expresión

$$r = \frac{2t_{(1-\alpha/2)}^2 S^2}{d^2}, \quad (5.14)$$

donde S^2 es la varianza estimada del error experimental, $t_{(1-\alpha/2)}$ es un valor que se obtiene de la tabla A.2, con un nivel $(1 - \alpha/2)$ y grados de libertad

asociados con S^2 , y d es la diferencia específica deseada entre dos medias de tratamientos.

El tamaño de muestra cuando $\Delta = \mu_1 - \mu_2$ es estimado por $\Delta_d = \bar{y}_1 - \bar{y}_2$, siendo

$$V(\Delta_d) = \frac{\sigma_1^2}{r_1} + \frac{\sigma_2^2}{r_2}.$$

Al asumir que $\sigma_1^2 = \sigma_2^2 = \sigma^2$ y $r_1 = r_2 = r$, la estimación del tamaño de muestra, con un nivel de precisión d y una confiabilidad $(1 - \alpha)$, se obtiene a través del siguiente procedimiento:

$$P[|\Delta - \Delta_d| \leq d] = 1 - \alpha \quad (5.15)$$

Obsérvese que

$$\frac{\Delta - \Delta_d}{\sigma \sqrt{(1/r + 1/r)}} \leq \frac{d}{\sigma \sqrt{(1/r + 1/r)}}.$$

Entonces, (5.15) puede ser escrito como

$$P\left(\frac{\Delta - \Delta_d}{\sigma \sqrt{(2/r)}} \leq \frac{d}{\sigma \sqrt{(2/r)}}\right) = 1 - \alpha/2. \quad (5.16)$$

Además, ya se conoce

$$\frac{\Delta - \Delta_d}{\sigma \sqrt{(1/r + 1/r)}} \sim N(0, 1)$$

Finalmente, de (5.15) se obtiene

$$r = \frac{2Z_{(1-\alpha/2)}^2 \sigma^2}{d^2}. \quad (5.17)$$

Con los valores obtenidos en (5.14) y (5.17) no se garantiza que la longitud del intervalo sea de tamaño $2A$, es decir, que

$$E[\text{long } IC] \leq 2A$$

es equivalente a

$$E[(\sqrt{2}S/\sqrt{r})t_{(1-\alpha/2)}] = A,$$

entonces

$$A = \frac{\sqrt{2}t_{(1-\alpha/2)}}{\sqrt{r}} E(S) = \frac{t_{(1-\alpha/2)}}{\sqrt{r}} \frac{2}{\sqrt{(r-1)}} \frac{\sigma \Gamma[r/2]}{\Gamma[(r-1)/2]}, \quad (5.18)$$

donde $E(S)$ se obtiene a partir del siguiente procedimiento:

Sea $Y = \frac{(r-1)S^2}{\sigma^2} \sim \chi^2_{(r-1)}$, entonces

$$\begin{aligned} f_Y(Y) &= \frac{1}{2^{(r-1)/2} \Gamma[(r-1)/2]} Y^{\frac{(r-1)}{2}-1} e^{-Y/2} I_{(0,\infty)}(Y) \\ E(\sqrt{Y}) &= \frac{1}{2^{(r-1)/2} \Gamma[(r-1)/2]} \int_0^\infty Y^{\frac{1}{2}} Y^{\frac{(r-1)}{2}-1} e^{-Y/2} dy \\ &= \frac{2^{r/2} \Gamma(r/2)}{2^{(r-1)/2} \Gamma[(r-1)/2]} \int_0^\infty \frac{1}{2^{r/2} \Gamma(r/2)} Y^{\frac{r}{2}-1} e^{-Y/2} dy \\ &= \frac{2^{r/2} \Gamma(r/2)}{2^{(r-1)/2} \Gamma[(r-1)/2]} = \frac{\sqrt{2} \Gamma(r/2)}{\Gamma[(r-1)/2]}, \end{aligned}$$

pero $\sqrt{Y} = \sqrt{(r-1)S/\sigma}$, entonces

$$E(\sqrt{Y}) = E((\sqrt{(r-1)S/\sigma})) = \frac{\sqrt{2} \Gamma(r/2)}{\Gamma[(r-1)/2]}.$$

De esta forma, se tiene que

$$E(S) = \frac{\sigma \sqrt{2} \Gamma(r/2)}{\sqrt{(r-1)} \Gamma[(r-1)/2]},$$

completando así la expresión (5.18).

5.7.1. Obtención del tamaño de la muestra a partir de la potencia

En arreglos de DCA, a menudo el investigador está interesado en determinar el número de réplicas que le permitan detectar diferencias significativas entre los tratamientos, es decir, determinar si hay o no evidencia para que con la prueba F del análisis de varianza se rechace o no la hipótesis nula.

La técnica desarrollada en la teoría estadística para decidir sobre el número de réplicas necesarias en un experimento es el cálculo de la potencia de las pruebas estadísticas de interés. En la prueba F del ANOVA a una vía, el cálculo directo de la potencia es generalmente complejo, pero se han construido algunas gráficas, llamadas curvas características de operación, que permiten estimar un valor para la probabilidad β o error de tipo II. La potencia $1 - \beta$ se deduce a partir de esta probabilidad.

Tang (1938) desarrolló un procedimiento y preparó las tablas necesarias para determinar el número de réplicas a ser usado en un experimento. Asume que la variación de la componente del error se distribuye en forma normal con media cero y varianza σ^2 . Para obtener el número adecuado de réplicas,

se requiere un buen estimador de σ^2 y que la diferencia verdadera del efecto medio de tratamiento $\alpha_i = \mu_i - \mu$ se especifique.

La sensibilidad de la prueba F o poder de la prueba, denotado por $1 - \beta$, donde β es la probabilidad del error tipo II, depende de:

- i) El tamaño del test, es decir, de la probabilidad del error tipo I (α).
- ii) De los grados de libertad ($t - 1$) y $t(r - 1)$ (en el caso de una vía de clasificación).
- iii) Del parámetro de no centralidad que se relaciona con

$$\phi_{\beta, \alpha}^2 = \frac{r \sum \alpha_i^2}{t\sigma^2} \quad (5.19)$$

en la distribución F -no central, donde los α_i son los valores verdaderos del efecto de tratamientos especificado bajo la hipótesis alterna. En el procedimiento general se especifica α , $1 - \beta$ y ϕ/r y se formula la pregunta: ¿cuántas réplicas, r , son necesarias para detectar con probabilidad $1 - \beta$ diferencias de tratamientos especificados por ϕ/r si se usa una prueba de tamaño α ?

El número de réplicas en el modelo I se obtiene haciendo uso de las gráficas construidas por Pearson y Hartley, las cuales se encuentran reproducidas en varios textos aunque con ligeras modificaciones, por ejemplo en Kempthorne (1952), Scheffé (1959), Neter, Wasserman y Kutner (1990), y Montgomery (2003). En este texto se presentan las tablas de este último autor. Las curvas fueron construidas para dar el valor β en la ordenada cuando se proponen valores de un parámetro ϕ sobre la abscisa y se asumen valores conocidos de α , v_1 y v_2 . El parámetro $\phi_{\beta, \alpha}$ se llama parámetro de no centralidad de la distribución F y es una medida del grado de desigualdad de los α_i .

En este caso, no se dificulta la especificación de α y β . Usualmente se toma $\alpha = 0.05$ ó $\alpha = 0.10$ como valores razonables para evaluar el riesgo de cometer el error tipo I, es decir, concluir que hay diferencias en los efectos de los tratamientos cuando realmente no existen estas diferencias.

Un paso más difícil es la escogencia de β ó $1 - \beta$, es decir, la probabilidad de detectar diferencias entre los tratamientos cuando verdaderamente existen estas diferencias. Es razonable escoger $1 - \beta = 0.80$, aunque la escogencia de este debe depender del problema que se esté tratando. La escogencia más difícil es la de ϕ/r porque esta representa el verdadero estado de la naturaleza. Para esta escogencia, el conocimiento que el investigador tenga del material experimental es bien importante.

Ejemplo 5.8. *Se va a determinar el número de réplicas para un experimento similar al del ejemplo 5.1, suponiendo que la potencia no debe ser inferior a 0.80. Asignando los mismos valores del ejemplo citado a los parámetros, se tiene*

$$\alpha = 0.05, \nu_1 = t - 1 = 3, \nu_2 = t(r - 1) = 16, \hat{\sigma}^2 = 10.36$$

y

$$\sum_{i=1}^t \hat{D}_i^2 = 1.13 + 16.28 + 14.94 + 0.80 = 33.15$$

Entonces,

$$\phi^2 = \frac{(5)(33.15)}{(4)(10.36)} = 4 \text{ y } \phi = 2.$$

En la figura A.1 del apéndice, en la gráfica, con $\nu_1 = 3$ y $\alpha = 0.05$ se localiza $\phi = 2$, desde este punto se sube hasta cortar la línea $\nu_2 = 16$ y al frente se lee la probabilidad $\beta \approx 0.16$. La potencia para el ejemplo 5.1 es por lo tanto de 0.84.

Si se quiere un experimento como el anterior pero con una potencia menor, se debe disminuir el número de réplicas r . Al suponer que $r = 4$ y calcular nuevamente la potencia para este valor, $\phi = 1.79$ y $\beta \approx 0.21$. Con 4 réplicas por tratamiento, la potencia sería de 0.79, que no cumple con la condición inicial, por lo cual sería recomendable tomar 5 réplicas para un estudio futuro en donde se tengan los mismos intereses experimentales.

En el ejemplo anterior, el procedimiento resulta inmediato porque se conocen todos los parámetros. En una situación real, el problema es más complejo, ya que ϕ no es calculable directamente. El valor de r es precisamente el valor que se desea conocer, la varianza σ^2 es igualmente desconocida y los α_i no son estimables antes de realizar el experimento.

En este proceso, el primer paso es la estimación de σ^2 . Si se conocen experimentos similares realizados con anterioridad, se puede reemplazar σ^2 por CME. En otro caso, debe hacerse un estimativo razonable mediante la información que posea el investigador, pues se supone que este no está partiendo de cero, sino que tiene algún conocimiento previo del comportamiento del fenómeno que se está queriendo evaluar.

Si fuera posible proponer valores para los α_i , se calcularía la suma de los cuadrados como en el ejemplo anterior. Lo más frecuente es no tener valores individuales para estos efectos.

Cuando no se tiene mayor conocimiento acerca de la naturaleza del experimento, se debe preguntar por la diferencia mínima entre los dos extremos de los tratamientos (el mejor y el peor) para detectar con probabilidad al menos de $1 - \beta$ si tal diferencia existe. Luego, otra alternativa es que el investigador especifique la diferencia mínima que considera significativa entre

las dos medias poblacionales más distantes y con base en este valor (llamado Δ) determinar el número de réplicas.

Si se denota por $\Delta = \alpha_{\text{máx}} - \alpha_{\text{mín}}$, para $i = 1, \dots, t$, el menor ϕ/r es obtenido con los $(t - 2)$ efectos de tratamientos restantes $\alpha_i = \frac{\alpha_{\text{máx}} + \alpha_{\text{mín}}}{2}$ siempre que $\sum_i \alpha_i = 0$.

Esto significa que $\alpha_{\text{máx}} = -\alpha_{\text{mín}}$, luego $\alpha_{\text{máx}} = \frac{\Delta}{2}$, $\alpha_{\text{mín}} = -\frac{\Delta}{2}$ y $\alpha_i = 0$ en otro caso, teniendo en cuenta el parámetro de no centralidad, entonces un valor tentativo para ϕ se obtiene a partir de la expresión propuesta por Scheffé (1959)

$$\Phi^2 = \frac{2r \frac{\Delta^2}{4}}{t\sigma_\epsilon^2} = \frac{r\Delta^2}{2t\sigma_\epsilon^2}. \quad (5.20)$$

Como la prueba F es una función creciente para Φ , entonces el poder de la prueba F , dada en (5.20), toma el menor valor para todas las diferencias.

En los casos prácticos hay que proceder un poco a la inversa en la estimación de r . Se parte de un valor de r más o menos grande y se encuentra el valor de Φ correspondiente a una potencia establecida. Conocido el valor de Φ , se despeja r de la fórmula (5.20) y se obtiene una primera aproximación a su valor. Se estima la potencia correspondiente a este valor de r , si resulta menor que la establecida, debe aumentarse el valor de r , y si resultara mayor, disminuirla.

Ejemplo 5.9. *Considere un estudio en el cual se detecta como significativa una diferencia entre medias igual o mayor a 3 kilogramos, es decir, $\Delta = 3$. Supóngase que se estimó la varianza en $\hat{\sigma}^2 = 10.36$. Hay $t = 4$ tratamientos para comparar y se requiere una potencia de 0.80. Entonces,*

$$\Phi^2 = \frac{9r}{(8)(10.36)} = 0.1086r.$$

Iniciando con $r = 15$, en la figura A.1 del apéndice con $v_1 = 3$ y $\alpha = 0.05$ se localiza $\beta = 0.20$ y para $v_2 = (4)(14) = 56$ se lee $\Phi \simeq 1.72$. Entonces, $\Phi^2 = 2.96$ y el r despejado es 27.26. Se repite el proceso con $r = 27$, de modo que $\Phi = \sqrt{(0.1086)(27)} = 1.71$ y $v_2 = (4)(26) = 104$. Estos valores dan una probabilidad $\beta \simeq 0.20$, se concluye que se requieren 27 individuos como mínimo por tratamiento si se desea una potencia de 0.80 para la prueba F asumiendo diferencias de 3 kilogramos o mayores entre medias poblacionales como significativas.

El número de réplicas r es muy sensible a la variación en los parámetros Δ y σ , como también a la potencia requerida. Para ilustrar esto, si α y v_1 son fijos, en la tabla 5.13 se observará cómo varía r .

Al crecer el número de réplicas r también crece la potencia. Para una potencia fija, se puede disminuir r si se aumenta Φ . Pero el parámetro Φ depende básicamente del

Tabla 5.13: Valores de r para diferentes valores de los parámetros Δ , σ y $1 - \beta$

Δ	σ^2	$1 - \beta$	r	Φ	β
3	10.36	0.80	27	1.71	0.20
2	10.36	0.80	61	1.72	0.20
3	8.50	0.80	22	1.71	0.20
3	10.36	0.90	35	1.95	0.10
4	8.50	0.82	14	1.81	0.18

cociente $\frac{\Delta}{\sigma}$, el cual puede aumentar ya sea porque la varianza es pequeña o porque la diferencia significativa se asume grande. Diferencias grandes entre las α_i son fáciles de detectar con pocos datos. Como no hay mucha precisión en cuanto a la varianza estimada, es aconsejable investigar varios tamaños de muestra dentro de un rango probable de valores de σ^2 antes de decidirse por un tamaño definitivo.

En Bowman y Kastenbaum (1975), se presentan los diferentes tamaños de muestra (r) para $1 - \beta$, $\Delta^* = \frac{\alpha_{\max} - \alpha_{\min}}{\sigma_\epsilon}$ y t dados (véase tabla A.8 del apéndice). En la obtención se utilizan básicamente los mismos argumentos presentados en (5.20), es decir, la diferencia mínima estandarizada.

Ejemplo 5.10. Suponga que se tiene un estudio con $t = 5$ tratamientos, $\alpha = 0.05$ para diferentes valores de $1 - \beta = 0.7, 0.8$ y 0.9 , $\Delta^* = 0.75, 1.0, 1.25$. Con estas especificaciones, se obtiene la tabla 5.14 para el número de réplicas r .

Tabla 5.14: Número de réplicas en un DCA

		Δ^*			
		r	0.75	1.0	1.25
$1 - \beta$	0.7	33	19	13	
	0.8	40	23	15	
	0.9	52	30	20	

Con base en los resultados obtenidos en la tabla 5.14, el número de unidades experimentales por tratamiento varía entre 14 y 56 réplicas. En todos los casos, el número de réplicas es muy grande. Además, para detectar pequeñas diferencias se requieren más réplicas, lo cual no es apropiado, ya que en la práctica muy seguramente no se pueden realizar tantas réplicas.

5.7.2. Método de Harris-Hurvitz-Mood (HHM)

Este método determina el número de réplicas requerido para obtener la significación en una proporción específica de experimentos, en la cual diferencias grandes o mayores que algunos valores de d preestablecidos existen. Se asume que los valores dentro de cada población se distribuyen en forma normal con varianza común para todas las poblaciones, las cuales tienen como estimador S_1^2 y df_1 grados de libertad.

Conociendo los valores de S_1^2 , df_1 y d , el número de réplicas requerido, con un nivel α de significación, se obtiene a partir de la expresión

$$r = 2(df_2 + 1)(K'S_1/d)^2,$$

donde K' es el valor de la tabla A.9 del apéndice y df_2 los grados de libertad estimados del segundo estimador de la varianza población S_2^2 .

Si r es demasiado pequeño para dar la estimación de df_2 , el menor valor de df_2 debe emplearse.

Ejemplo 5.11. Los datos de un experimento sobre cantidad de grasa absorbida por 64 buñuelos para diferentes tipos de grasa se muestran en la tabla 5.15.

Tabla 5.15: Diferencias entre las medias de grasa absorbidas por buñuelos

Cantidades de grasa	Medias	4	3	2	6	1	5	8
		185	182	178	176	172	165	162
7	161	24	21	17	15	11	4	1
8	162	23	20	16	14	10	3	–
5	165	20	17	13	11	7	–	–
1	172	13	16	6	4	–	–	–
6	176	9	6	2	–	–	–	–
2	178	7	4	–	–	–	–	–
3	182	3	–	–	–	–	–	–

Suponga que se encontró $S_1^2 = 141.6$, con $df_1 = 40$ grados de libertad. Al asumir que $d = 20$, $1 - \beta = 80\%$ e incluyendo solamente 6 tratamientos en el experimento, se obtiene

$$r = \frac{2(60 + 1)(0.322)^2(141.6)}{400} = 4.48$$

Observe que si $df_2 = 60$, entonces se sobreestiman los grados de libertad, en tanto que si $df_2 = 25$, es decir, subestimando los grados de libertad, se obtiene

$$r = \frac{2(25 + 1)(0.502)^2(141.6)}{400} = 4.64.$$

Por lo tanto, se necesitan 5 réplicas para alcanzar los resultados deseados en este experimento. Si $1 - \beta = 0.95$, entonces son necesarias más réplicas.

Ocasionalmente, el experimentador no define estimadores de varianza en la forma S_1^2 , pero conoce “algo” acerca de los órdenes de magnitud para relacionar la información con los límites superior e inferior de la desviación estándar dentro de las cantidades máximas S_1 y df_1 .

Harris, Horvitz y Mood (1948) proponen un procedimiento simple: primero el experimentador se cuestiona por los límites inferior y superior (S_I, S_S) de la desviación estándar. Suponiendo que él desea estimar 7 % y 12 % de la media para los límites superior e inferior, y la desviación estándar de la media es 30, entonces $S_I = (0.7)(30) = 2.1$ y $S_S = (0.12)(30) = 3.6$.

La estimación de la desviación estándar es el promedio de los dos estimadores

$$S_1 = (S_I + S_S)/2 = 2.85$$

Para obtener df_1 es necesario que el investigador tenga alguna “confianza” sobre los estimadores. Se calculan los valores de $\sqrt{\chi_{(0.1)}^2 / \chi_{(0.9)}^2}$ para varios grados de libertad, el valor más cercano al cociente S_S/S_I se considera como los grados de libertad asociados con S_1 (df_1). Para el ejemplo $S_S/S_I = 1.72$ y de la tabla $\sqrt{\chi_{(12,0.1)}^2 / \chi_{(12,0.9)}^2} = 1.72$, de donde se asume que S_1 tiene asociados 12 grados de libertad, utilizando este valor se puede estimar r .

5.7.3. Método de Tukey

Un intervalo de confianza de $(1 - \alpha)100\%$ de longitud $\leq 2d$ para la diferencia de cualquier par de medias cuando se tiene un conjunto de t tratamientos se obtiene a partir de la expresión del siguiente proceso:

Si hay t medias (asociadas con los tratamientos), se hacen comparaciones dos a dos, es decir,

$$(\bar{Y}_{\text{máx}} - \bar{Y}_{\text{mín}}) / \sqrt{CME/r} \sim q_{(t, df_2)}.$$

Sea $P_0 \leq P$ la longitud del intervalo que cubre todas las diferencias $\leq 2d$. Entonces

$$P_0 = P(2Sq_{(1-\alpha)} / \sqrt{r} \leq 2d), \quad (5.21)$$

donde $S = \sqrt{CME}$ y $q_{(1-\alpha)}$ es el límite en la tabla A.12 del apéndice de rangos studentizados. De (5.21), se encuentra que

$$P_0 = P(S^2 \leq d^2 r / q_{(1-\alpha)}^2). \quad (5.22)$$

En la expresión (5.22), al dividir por un S^2 previo, S_1^2 , para obtener una F , se sigue

$$P_0 = P(S^2/S_1^2 \leq d^2 r / (q_{(1-\alpha)}^2 S_1^2)), \quad (5.23)$$

con $S^2/S_1^2 \sim F_{(df_2, df_1)}$. De (5.23), se obtiene

$$r = F_{(df_2, df_1, 1-\alpha)} S_1^2 q_{(t, df_2, 1-\alpha/2)}^2 / d^2. \quad (5.24)$$

Ejemplo 5.12. Retomando el ejemplo 5.11, sea $S_1^2 = 141.6$, $df_1 = 40$ y $d = 20$. Los valores de glE y $q_{(t, df_2, 1-\alpha)}$ dependen del diseño y de los valores de $1 - \beta$. Si se supone S_1 como en el diseño completamente aleatorizado con $r = 6$, $t = 6$, $1 - \beta = 0.9$ y $df_2 = 30$, entonces $gl(total) = 35$, $gl(tratamientos) = 5$ y $glE = 30$. Así, $F_{(30, 40, 0.10)} = 1.54$ y $q_{(5, 30, 0.10)} = 4.30$, donde q corresponde al valor apropiado en la tabla A.12 de rangos estudentizados. Con estos resultados y de la ecuación (5.24), se obtiene

$$r = \frac{(141.6)(4.30)^2(1.54)}{400} = 10.08.$$

Para este caso, el estimador es sesgado. Si se desea garantizar que la longitud del intervalo sea $2A$, entonces de (5.18) se encuentra

$$r = \frac{2\sigma^2 t_{1-\alpha/2}^2 \Gamma^2\left(\frac{r}{2}\right)}{A^2(r-1) \Gamma^2\left(\frac{r-1}{2}\right)}.$$

Como el valor de df_2 fue subestimado, se toma $r = 9$, entonces $df_2 = 48$, $q_{(5, 48, 0.90)} = 4.2$, $F_{(48, 40, 0.10)} = 1.48$ y $r = 9.2$.

Como el valor de $r > 9$, entonces con $r = 10$, lo suficientemente grande para esta propuesta, se puede obtener un intervalo de confianza con 10 réplicas y el 95% de confianza, el cual es mayor que $2d$ en longitud en el 90% de los experimentos.

Ejemplo 5.13. Se desean comparar 8 medias (dos a dos) de tratamientos sobre rendimiento en trigo, se rechaza la igualdad si la diferencia es mayor que 500. Se encuentra el número de réplicas para $\alpha = 0.10$ (probabilidad de rechazo cuando la diferencia es menor que 8) y con un $S_1^2 = 90000$ con 200 grados de libertad. Es necesario suponer un diseño, por ejemplo, completamente aleatorizado o bloques completos aleatorizados para así facilitar el cálculo de los grados de libertad del error. Además, se supone que son satisfechos los supuestos de normalidad, independencia de los errores y demás supuestos. En este caso,

$$|\bar{Y}_i - \bar{Y}_j| > 500,$$

entonces $d = 500$, $S_1^2 = 90000$, $t = 8$, $df_1 = 200$, $d^2 = 250000$, $\alpha = 0.10$ y $1 - \beta = 0.75$.

Si $r = 4$, entonces $glE = (8)(3) = 24$, utilizando Tukey se encuentra $r = 6.25$. Si $r = 5$, entonces $glE = (8)(4) = 32$, luego, $r = 6.30$. Si $r = 6$, entonces $glE = (8)(5) = 40$, luego, $r = 6$.

De acuerdo con los resultados anteriores, se puede concluir que con las especificaciones planteadas se necesitan 6 réplicas para encontrar las diferencias de medias deseadas.

5.7.4. Número de réplicas en el modelo de efectos aleatorios

La potencia de la prueba F del ANOVA para el modelo de efectos aleatorios está basada en la distribución F , pero la determinación de su valor resulta más simple usando las curvas características de operación. Estas curvas, como las del modelo I (efectos fijos), dan valores de β en la ordenada para diferentes valores del parámetro

$$\lambda = \sqrt{1 + \frac{r\sigma_A^2}{\sigma^2}}$$

en la abscisa.

Ejemplo 5.14. *Para los datos del ejemplo 5.5, la potencia de la prueba F se obtiene teniendo en cuenta los parámetros y estimadores $\alpha = 0.05$, $\nu_1 = t - 1 = 4$, $\nu_2 = \sum_{i=1}^t (n_i - 1) = 30$, $\hat{\sigma}_A^2 = 158.015$, $\hat{\sigma}^2 = 416.214$ y $r_0 = 6.97 \simeq r$.*

El método es válido únicamente para grupos iguales, pero se hace una aproximación con r_0 para conservar los valores del ejemplo citado. Con los anteriores datos se calcula el parámetro $\lambda = 1.91$. En la gráfica A.2 del apéndice se lee, para este λ , una probabilidad $\beta \simeq 0.50$, es decir, que la potencia es 0.50. La potencia calculada es muy baja debido al reducido número de réplicas. Si se quisiera repetir este experimento fijando una potencia de 0.80 y con los mismos parámetros para el cálculo de r (grupos iguales), se procede de la siguiente forma:

Se fija un valor para r , por ejemplo 15, entonces $\nu_2 = 5 \times 14 = 70$. Con $\beta = 0.20$ se lee en la gráfica el valor $\lambda \simeq 2.30$, despejando r de la fórmula para λ se obtiene $r = \frac{(\lambda^2 - 1)\hat{\sigma}_A^2}{\hat{\sigma}_A^2} = 11.29$. Se ensaya con $r = 11$ y se calcula un nuevo $\lambda = 2.27$. Con $\nu_2 = 50$, se encuentra un $\beta \simeq 0.24$. Como β debe ser 0.20, se aumenta r a 12 y se realiza otro ensayo; para este r se tiene un $\lambda = 2.35$, $\nu_2 = 55$ y $\beta \simeq 0.20$. Así que, para lograr una potencia de 0.80, se requiere un mínimo de 12 réplicas por tratamiento. Los tamaños de muestra obtenidos son aproximados, dependen, entre otras cosas, de las lecturas visuales en las gráficas, las cuales pueden variar de una persona a otra.

Las siguientes observaciones sobre el número de réplicas complementan la discusión anterior y sirven de guía para estudios posteriores.

1. Bajo condiciones similares, el tamaño de muestra es mayor para el modelo II que para el modelo I, porque en el modelo II se estiman parámetros cuadráticos mientras en el modelo I los parámetros son lineales.
2. En lo posible, se deben diseñar experimentos con igual número de réplicas por grupo, sobre todo si se planean comparaciones de medias por pares, como se verá en el capítulo 6, así se obtiene mayor precisión en las comparaciones y mayor potencia.
3. Si en el experimento se incluye un tratamiento control, este deberá tener mayor número de réplicas.
4. Si el número de réplicas se ha fijado de antemano, el cálculo de la potencia para al ANOVA permite ahorrar tiempo y esfuerzo, en tanto que para una potencia baja es preferible no realizar el experimento, puesto que de él se concluiría muy poco. La situación anterior tiene un paralelo con el caso de la persona que desea pesar, por ejemplo, una moneda (colombiana) y solo dispone de una balanza graduada de 100 en 100 gr. Puede efectuar la medición pero al resultado es tan incierto que sería casi igual a no usar dicha balanza.
5. Si el experimento se realizó, es útil preguntarse por la potencia de la F en el ANOVA, sobretodo si la hipótesis H_0 no ha sido rechazada; vale la pena conocer cuál sería el error tipo II.
6. Puede ocurrir que el número total de unidades experimentales esté limitado y que no todos los tratamientos puedan incluirse en el experimento. El problema se convierte en determinar el valor máximo de t que garantice una potencia dada. El valor t puede hallarse por ensayo y error conociendo los demás valores de la ecuación para el parámetro ϕ . Debe tenerse en cuenta que la potencia disminuye al aumentar el número de tratamientos.

5.7.5. Determinación del tamaño de muestra con costo variable por tratamiento

Asumiendo que los costos por tratamiento ($c_i > 0$) son variables, bajo la restricción $\sum_{i=1}^t c_i r_i = C$ y teniendo que

$$Var(MELI(L)) = \sum_{i=1}^t \lambda_i^2 \frac{\sigma_i^2}{r_i}, \quad (5.25)$$

donde $L = \sum_{i=1}^t \lambda_i \mu_i$ y

$$MELI(L) = \sum_{i=1}^t \lambda_i \bar{y}_i, \quad (5.26)$$

con la restricción impuesta anteriormente, se minimiza la función lagrangiana

$$Q = \sum_{i=1}^t \frac{\lambda_i^2 \sigma_i^2}{r_i} + \varphi \left(\sum_{i=1}^t r_i c_i - C \right). \quad (5.27)$$

Al solucionar la ecuación (5.27), se sigue que

$$r_i = \frac{|\lambda_i| \sigma_i}{\sqrt{\varphi c_i}}, \quad i = 1, \dots, t, \quad (5.28)$$

donde $\varphi = \frac{1}{C^2} \left(\sum_{i=1}^t |\lambda_i| \sigma_i \sqrt{c_i} \right)^2$. Es recomendable que los coeficientes lineales de λ_i estén expresados en términos de fracciones para facilitar el cálculo de los tamaños de muestra en (5.28).

Si en la asignación de las observaciones de los tratamientos se tiene en cuenta la fijación proporcional de las desviaciones estándar, conociendo n , entonces

$$\tilde{r}_i = \frac{n \sigma_i}{\sum_{s=1}^t \sigma_s}, \quad i = 1, \dots, t. \quad (5.29)$$

Ejemplo 5.15. *De Campos (1984) presenta los siguientes datos referentes a la producción en toneladas por hectárea de cuatro variedades de caña de azúcar:*

	V_1	V_2	V_3	V_4
	78.82	56.60	105.12	96.89
	86.80	63.82	112.94	90.91
	68.65	58.71	108.12	92.97
	77.76	70.59	121.10	97.98
	75.80	81.74	115.87	95.93
Media	76.7	67.40	109.10	92.80
Desviación	6.27	9.57	12.0	3.32

Se observa que hay una proporcionalidad en las desviaciones estándar, entonces, por (5.29), los tamaños de muestra adecuados para cada variedad serían

$$\tilde{r}_1 = 4, \quad \tilde{r}_2 = 6, \quad \tilde{r}_3 = 8, \quad \tilde{r}_4 = 2.$$

Si además se tuviera interés en llevar a cabo la prueba de la hipótesis

$$H_0 : L = 0, \quad \text{siendo} \quad L = \mu_4 - \frac{1}{3}(\mu_1 + \mu_2 + \mu_3),$$

de (5.26), $\hat{L} = 8.4$, y de (5.25), $\widehat{V(\hat{L})} = 13.34$. Teniendo, finalmente, $\frac{\hat{L}}{\sqrt{\widehat{V(\hat{L})}}} = 2.29$, que al confrontarlo con una t , $t(f, 0.05)$, siendo

$$f = \frac{(S_1^2 + S_2^2 + S_3^2 + S_4^2)^2}{\frac{1}{16} [(S_1^2)^2 + (S_2^2)^2 + (S_3^2)^2 + (S_4^2)^2]} = 42.48$$

grados de libertad ($t_{(42, 0.05)} = 1.68$), se rechaza la hipótesis nula.

En el modelo de componentes de varianza tanto el número de tratamientos t como el número de réplicas r son variables y sus estimaciones están ligadas con el control de dichas varianzas. Un criterio usual para elegir los valores de r y t es el de minimizar los costos en la estimación de la media μ . Una medida de la cantidad de información disponible para estimar μ es la varianza de la media muestral dada por $v(\bar{y}_{..}) = \frac{\sigma^2}{rt} + \frac{\sigma_A^2}{t}$ (en el caso de un DCA).

El problema se reduce a encontrar los valores de r y t que minimicen la función de costos dada por $C = C_1t + C_2tr$ para una varianza $v(\bar{y}_{..})$ fija, en donde C_1 es el costo por unidad de tratamiento y C_2 es el costo por unidad experimental. La solución matemática es, según Mendenhall (1968),

$$t = \frac{1}{v(\bar{y}_{..})} \left(\hat{\sigma}_A^2 + \sqrt{\frac{\hat{\sigma}_A^2 \hat{\sigma}^2 C_2}{C_1}} \right) \quad \text{y} \quad r = \sqrt{\frac{\hat{\sigma}^2 C_1}{\hat{\sigma}_A^2 C_2}}.$$

Ejemplo 5.16. Con los datos del ejemplo 5.5 y suponiendo una varianza máxima $V(\bar{y}_{..}) = 43.49$, $C_1 = \$150000$ y $C_2 = \$50000$, se encuentra que:

$$t = \frac{1}{43.49} \left(158.015 + \sqrt{\frac{(158.015)(416.21)(50000)}{150000}} \right) = 7.04$$

$$r = \sqrt{\frac{(416.21)(150000)}{(158.015)(50000)}} = 2.81.$$

Para una varianza de la media muestral no mayor de 43.49 deberían seleccionarse 7 toros y 3 terneros por cada toro en un experimento similar al del ejemplo 5.5, asumiendo que el costo experimental de cada toro es de \$150.000 y el de cada ternero es de \$50.000.

Otros enfoques interesantes sobre la estimación del tamaño muestral en ANOVA se encuentran, por ejemplo, en Sokal y Rohlf (1969) y en Neter et al. (1990).

5.8. Submuestreo en diseños completamente aleatorizados

Como se describió en el capítulo 1, se debe hacer una clara distinción entre unidades experimentales (UE) y unidades muestrales observacionales (UO). En este capítulo, hasta ahora se ha considerado la situación en que las UE y UO son idénticas. Una consecuencia de esta situación es que a través de la formulación de un modelo lineal para las observaciones de un diseño completamente aleatorizado (DCA) se debe diferenciar entre error experimental (ϵ_{ij}) y error observacional (η_{ijk}), pero hasta ahora no se pueden separar los dos términos del error en el análisis y, por ello, estos se combinan dentro de un solo término de error (e_{ij}). Existen, sin embargo, situaciones en donde las UE's no son iguales a las UO's. Por ejemplo, en un estudio sobre el rendimiento académico de los diferentes cursos en un colegio, los estudiantes de un curso son las UE's y los estudiantes individuales dentro del curso son la UO's. Esta situación es generalmente vista como un caso de un DCA con submuestreo.

5.8.1. Modelo lineal en un DCA con submuestreo

Suponga que se tienen t tratamientos, cada uno replicado r' veces; cada UE tiene n observaciones. Con esto se tiene una extensión del modelo (5.2) como

$$y_{ijk} = \mu + \alpha_i + \epsilon_{ij} + \eta_{ijk}, \quad (5.30)$$

con $i = 1, \dots, t$, $j = 1, \dots, r'$ y $k = 1, \dots, n$; donde ϵ_{ij} representa el error experimental y η_{ijk} el error observacional (error de muestreo). Además, se asume que $\epsilon_{ij} \stackrel{iid}{\sim} N(0, \sigma_\epsilon^2)$, $\eta_{ijk} \stackrel{iid}{\sim} N(0, \sigma_\eta^2)$ y $Cov(\epsilon_{ij}, \eta_{ijk}) = 0$, para todo ijk . Por consiguiente,

$$Var(y_{ijk}) = \sigma_\epsilon^2 + \sigma_\eta^2 = \sigma_e^2.$$

Justamente, como en el modelo (5.2), excepto que ahora se han separado las dos componentes de varianza. Como en este caso las UE's están anidadas dentro de los tratamientos y las UO's están anidadas dentro de las UE's (véase capítulo 1 y 4), entonces para el modelo (5.30) se tiene el ANOVA que se muestra en la tabla 5.16, el cual se obtiene a partir de la siguiente identidad:

$$y_{ijk} = \bar{y}_{...} + (\bar{y}_{i..} - \bar{y}_{...}) + (\bar{y}_{ij.} - \bar{y}_{i..}) + (y_{ijk} - \bar{y}_{ij.}).$$

Tabla 5.16: ANOVA para un DCA con submuestreo

C de V	gl	SC	CM	E(CM)
Tratamientos	$t - 1$	$r'n \sum_i (\bar{y}_{i..} - \bar{y}_{...})^2 = SCTrat$	$CMTrat$	$\sigma_\eta^2 + n\sigma_\epsilon^2 + \frac{r'n}{t-1} \sum_i \alpha_i^2$
Error exp.	$t(r' - 1)$	$n \sum_{ij} (\bar{y}_{ij.} - \bar{y}_{i..})^2 = SCEE$	$CMEE$	$\sigma_\eta^2 + n\sigma_\epsilon^2$
Error obs.	$tr'(n - 1)$	$\sum_{ijk} (y_{ijk} - \bar{y}_{ij.})^2 = SCEO$	$CMEO$	σ_η^2
Total	$tr'n - 1$	$\sum_{ijk} (y_{ijk} - \bar{y}_{...})^2$		

5.8.2. Inferencias con submuestreo

Con base en los resultados obtenidos en la tabla 5.16, si se desea contrastar la hipótesis nula de no diferencias entre tratamientos, se encuentra como estadístico de prueba

$$F = \frac{CMTrat}{CMEE} \sim F_{(t-1, t(r'-1))},$$

rechazándose H_0 si $F_c > F_{(t-1, t(r'-1))}$. Adicionalmente, se pueden estimar las componentes de varianza separadamente de la siguiente forma

$$\hat{\sigma}_\eta^2 = CMEO$$

y

$$\hat{\sigma}_\epsilon^2 = \frac{CMEE - CMEO}{n}.$$

El uso de algunas observaciones por UE, es decir, submuestras, no constituye replicación de tratamientos y los grados de libertad del estadístico F se determinan mediante t y r' , y no por n , por consiguiente, una pregunta de interés es ¿cuáles son los beneficios de hacer submuestreo en el experimento? Esta pregunta se puede responder afirmando que se logra la separación de las componentes de varianza del error experimental y muestral, las cuales expresan la calidad del experimento en términos de variabilidades (componentes de varianza). Si por ejemplo se encuentra que σ_η^2 es muy grande, se podría tratar de mejorar el proceso de medición; o si σ_ϵ^2 es grande, se deben considerar otras UE y, a partir de su homogeneidad, se debe decidir el uso de información complementaria, por lo que otro diseño puede ser más apropiado.

Ejemplo 5.17. Considere el ejemplo 4.2 del capítulo 4.

5.9. Comparación de un DCA sin y con submuestreo

En la sección 5.7, el número de réplicas r requerido puede ser grande, de hecho, mucho más grande de lo que puede ser posible tanto económicamente como en las condiciones del experimento. Se puede pensar que el submuestreo, aunque no es un sustituto de la replicación, puede ser de gran ayuda. Para ilustrar esta situación, suponga que se tienen las siguientes dos situaciones:

Plan I. DCA con r réplicas y no submuestreo, es decir, $r' = r$, $n = 1$.

Plan II. DCA con r' réplicas y submuestreo de $n > 1$ UO por UE, con $r' < r$.

En el plan I, el estadístico F se basa en $t(r - 1)$ grados de libertad en el denominador y el parámetro de no-centralidad es:

$$\lambda_I = \frac{r \sum_{i=1}^t \alpha_i^2}{t(\sigma_\epsilon^2 + \sigma_\eta^2)}, \quad (5.31)$$

mientras para el plan II, el estadístico F está basado en $t(r' - 1)$ grados de libertad en el denominador y parámetro de no-centralidad

$$\lambda_{II} = \frac{r'n \sum_{i=1}^t \alpha_i^2}{t(\sigma_\eta^2 + n\sigma_\epsilon^2)} \quad (5.32)$$

De esta forma, si la potencia de la prueba F crece con los grados de libertad y el parámetro de no-centralidad, el plan II puede ser mejor que el I si y solo si $\lambda_{II} > \lambda_I$, con $t(r' - 1) < t(r - 1)$. Exactamente esta comparación se realiza contrastando dos tratamientos a través de $Var(\bar{y}_{i..} - \bar{y}_{i'..})$, $i \neq i'$, $i, i' = 1, 2, \dots, t$.

Específicamente, se tiene

$$Var_I = \frac{2(\sigma_\epsilon^2 + \sigma_\eta^2)}{r}$$

y

$$\begin{aligned} Var_{II} &= \frac{2(\sigma_\eta^2 + n\sigma_\epsilon^2)}{r'n} \\ &= 2 \left(\frac{\sigma_\eta^2}{r'n} + \frac{\sigma_\epsilon^2}{r'} \right). \end{aligned} \quad (5.33)$$

Uno de los puntos importantes en un diseño experimental es reducir $Var(\bar{y}_{i..} - \bar{y}_{i'..})$. La expresión (5.33) muestra claramente que esto no puede lograrse solo incrementando n ; esto reduce solo una componente y usualmente es la menos importante. Por lo tanto, se debe considerar tanto r' como n en el diseño. Una relación útil, según Bowman y Kastenbaum (1975), entre r , r' y n puede obtenerse haciendo $\sigma_\eta^2 = \delta\sigma_\epsilon^2$ de la siguiente manera:

$$n = \frac{r\delta}{r'(1+\delta) - r} \quad (5.34)$$

o

$$r' = \frac{r(\delta + n)}{n(1 + \delta)}. \quad (5.35)$$

Si esta relación no se tiene, los tamaños de muestra pueden ser obtenidos mediante las relaciones (5.31) y (5.32), realizando los mismos procedimientos presentados en la sección 5.7.

La forma de utilizar las relaciones (5.34) y (5.35) es la siguiente:

- i. Con base en una apropiada escogencia de $\Delta^* = \frac{\alpha_{\max} - \alpha_{\min}}{\sigma_\epsilon}$, se encuentra r de la tabla A.8 del apéndice de Bowman y Kastenbaum (1975). Nótese que Δ^* no depende de la escogencia del diseño, es decir, el DCA sin o con submuestreo; en este caso, $\sigma_\epsilon = (\sigma_\epsilon^2 + \sigma_\eta^2)^{\frac{1}{2}}$.
- ii. Escoja un r' en una vecindad de r con $r' < r$.
- iii. Especifique un valor para δ basado en la evidencia empírica o teórica.
- iv. Use (5.34) para determinar un apropiado n , redondeando a valores enteros.

Ejemplo 5.18. Suponga $t = 5$, $\alpha = 0.05$, $1 - \beta = 0.80$ y $\Delta^* = 1.50$. De la tabla A.8 del apéndice, se encuentra $r = 12$. Para $\delta = 0.50, 0.75, 1.00$, la posible escogencia de r' y n se muestra en la tabla 5.17.

Tabla 5.17: Número de réplicas y tamaño de submuestras para $r = 12$

$\delta = 0.50$		$\delta = 0.75$		$\delta = 1.00$	
r'	n	r'	n	r'	n
11	2	11	2	11	2
10	2	10	2	10	2
9	4	9	3	9	2
		8	5	8	3
		7	36	7	6

De los resultados de la tabla 5.17, se concluye:

- i) Una escogencia limitada en el número de réplicas r' .
- ii) Cuando r' decrece, n crece rápidamente.
- iii) Cuando δ crece, se tienen más opciones para r' .
- iv) El número total de observaciones, $tr'n$, para el DCA con submuestreo es considerablemente más grande que el número total de observaciones, tr , para el DCA sin submuestreo.

Lo importante en esta discusión es que se deben tener opciones antes de seleccionar un experimento, teniendo en cuenta los puntos de interés del investigador, el material experimental y las limitaciones económicas de la investigación. Solamente entonces se pueden evitar “desastres” en las conclusiones al finalizar el experimento.

Finalmente, una alternativa para seleccionar los anteriores tamaños de muestra está dada por

$$n = \frac{r\sigma_{\eta}^2}{r' + r'\sigma_{\eta}^2 - r\sigma_{\epsilon}^2}$$

y

$$r' = \frac{r(\sigma_{\eta}^2 + n\sigma_{\epsilon}^2)}{n(\sigma_{\eta}^2 + \sigma_{\epsilon}^2)}.$$

5.10. Submuestreo con factores aleatorios en DCA

Considere el modelo

$$y_{ijk} = \mu + C_i + S_{ij} + \epsilon_{ijk}, \quad (5.36)$$

con $i = 1, \dots, t$, $j = 1, \dots, r$, $k = 1, \dots, n$, en donde C_i es el efecto de la unidad primaria de muestreo, S_{ij} es el efecto de la unidad secundaria de muestreo j en la unidad primaria i , ϵ_{ijk} es efecto aditivo debido a la observación k sobre la unidad secundaria j de la unidad primaria i y y_{ijk} es el valor de la observación.

Si la única componente fija del modelo es μ , entonces las variables aleatorias independientes satisfacen las siguientes propiedades:

- i. $E(C_i) = 0$, $V(C_i) = \sigma_c^2$.

$$\text{ii. } E(S_{ij}) = 0, \quad V(S_{ij}) = \sigma_s^2.$$

$$\text{iii. } E(\epsilon_{ijk}) = 0, \quad V(\epsilon_{ijk}) = \sigma_\epsilon^2.$$

El valor promedio de la característica observada es

$$\bar{y}_{...} = \frac{1}{trn} \sum_{ijk} y_{ijk}$$

y la varianza es

$$V(\bar{y}_{...}) = \frac{1}{(trn)^2} \sum_{ijk} V(y_{ijk}),$$

de donde se tiene que

$$V(\bar{y}_{...}) = \frac{\sigma_c^2}{t} + \frac{\sigma_s^2}{tr} + \frac{\sigma_\epsilon^2}{trn}, \quad (5.37)$$

Para el modelo (5.36), el diagrama de estructuras asociado se presenta en la figura 5.1.

$$\begin{array}{c} \mu \\ | \\ \underline{C} \\ | \\ \underline{S} \\ | \\ \epsilon \end{array}$$

Figura 5.1: Diagramas de estructuras para un diseño de factores aleatorios con submuestreo.

El análisis de varianza se presenta en la tabla 5.18. Además, como el modelo es de efectos aleatorios, la estructura de las componentes de varianza se presenta en la tabla 5.19.

De los resultados de los cuadrados medios esperados y los cuadrados medios del ANOVA, se obtiene:

$$\text{i. } \hat{\sigma}_\epsilon^2 = CME.$$

$$\text{ii. } \hat{\sigma}_S^2 = \frac{CMS - CME}{n}.$$

$$\text{iii. } \hat{\sigma}_C^2 = \frac{CMC - CMS}{rn}.$$

Tabla 5.18: Análisis de varianza con factores aleatorios y submuestreo en un DCA

C. de V.	GL	SC	CM
$C : \mu$	$t - 1$	$\frac{1}{rn} \sum_{i=1}^t y_{i..}^2 - \frac{y_{..}^2}{trn}$	CMC
$S : C\mu$	$(r - 1)t$	$\frac{1}{n} \sum_{ij} y_{ij.}^2 - \frac{1}{rn} \sum_{i=1}^t y_{i..}^2$	CMS
$\epsilon : SC\mu$	$(n - 1)tr$	$\sum_{ijk} y_{ijk}^2 - \frac{1}{n} \sum_{ij} y_{ij.}^2$	CME
Total	$trn - 1$	$\sum_{ijk} y_{ijk}^2 - \frac{y_{..}^2}{trn}$	

Tabla 5.19: Esperanza de los cuadrados medios para el modelo (5.36)

Efecto	i	j	k	E(CM)
C_i	1	r	n	$\sigma_{\epsilon}^2 + n\sigma_s^2 + rn\sigma_c^2$
$S_{j:i}$	1	1	n	$\sigma_{\epsilon}^2 + n\sigma_s^2$
ϵ_{kij}	1	1	1	σ_{ϵ}^2

5.10.1. Tamaño óptimo de muestra con un costo fijo (C_0)

En este caso, se busca minimizar la siguiente ecuación cuando los valores de t, r, n , satisfacen

$$C_0 = tC_1 + trC_2 + trnC_3. \quad (5.38)$$

Aplicando el método de los multiplicadores de Lagrange, se plantea la función

$$F_1 = \frac{\sigma_c^2}{t} + \frac{\sigma_s^2}{tr} + \frac{\sigma_{\epsilon}^2}{trn} + \lambda(C_0 - tC_1 - trC_2 - trnC_3).$$

Al derivar parcialmente, con respecto a t, r, n y λ , se llega al siguiente sistema de ecuaciones

$$\begin{aligned} \frac{\partial F_1}{\partial t} &= -\frac{\sigma_c^2}{t^2} - \frac{\sigma_s^2}{t^2 r} - \frac{\sigma_{\epsilon}^2}{t^2 rn} + \lambda(-C_1 - rC_2 - rnC_3) = 0 \\ \frac{\partial F_1}{\partial r} &= -\frac{\sigma_s^2}{tr^2} - \frac{\sigma_{\epsilon}^2}{tr^2 n} - \lambda(tC_2 + tnC_3) = 0 \\ \frac{\partial F_1}{\partial n} &= -\frac{\sigma_{\epsilon}^2}{trn^2} - \lambda trC_3 = 0 \\ \frac{\partial F_1}{\partial \lambda} &= C_0 - tC_1 - trC_2 - trnC_3 = 0. \end{aligned}$$

Al solucionar este sistema de ecuaciones, se obtiene que

$$r = \frac{\sigma_s}{\sigma_c} \sqrt{\frac{C_1}{C_2}}, \quad n = \frac{\sigma_\epsilon}{\sigma_s} \sqrt{\frac{C_2}{C_3}} \quad \text{y} \quad t = \frac{C_0}{C_1 + rC_2 + rnC_3}.$$

Con estos valores y un costo C_0 determinado, el muestreo va a ser más eficiente.

5.10.2. Muestra más económica para una precisión dada de estimación

Se busca minimizar (5.38), sujeto a (5.37), pero en este caso considerando a $V(\bar{y}_{...}) = V_0$, la precisión de la estimación.

Aplicando de nuevo los multiplicadores de Lagrange, se obtiene la función

$$F_2 = tC_1 + trC_2 + trnC_3 + \lambda \left(V_0 - \frac{\sigma_c^2}{t} - \frac{\sigma_s^2}{tr} - \frac{\sigma_\epsilon^2}{trn} \right).$$

Al derivar parcialmente, con respecto a t , r , n y λ , se llega a

$$\frac{\partial F_2}{\partial t} = C_1 + rC_2 + rnC_3 + \lambda \left(\frac{\sigma_c^2}{t^2} + \frac{\sigma_s^2}{t^2r} + \frac{\sigma_\epsilon^2}{t^2rn} \right) = 0$$

$$\frac{\partial F_2}{\partial r} = tC_2 + tnC_3 + \lambda \left(\frac{\sigma_s^2}{tr^2} + \frac{\sigma_\epsilon^2}{tr^2n} \right) = 0$$

$$\frac{\partial F_2}{\partial n} = trC_3 + \lambda \frac{\sigma_\epsilon^2}{trn^2} = 0$$

$$\frac{\partial F_2}{\partial \lambda} = V_0 - \frac{\sigma_c^2}{t} - \frac{\sigma_s^2}{tr} - \frac{\sigma_\epsilon^2}{trn} = 0$$

y al solucionar el anterior sistema de ecuaciones se encuentra que

$$t = \frac{rn\sigma_c^2 + n\sigma_s^2 + \sigma_\epsilon^2}{rnV_0}$$

$$n = \frac{\sigma_\epsilon}{\sigma_s} \sqrt{\frac{C_2}{C_3}}$$

$$r = \frac{\sigma_s}{\sigma_c} \sqrt{\frac{C_1}{C_2}}.$$

Ejemplo 5.19. Durante septiembre de 1950 el instituto para el mejoramiento de la producción de azúcar decidió determinar el grado de infestación debido al barrenador en la zona de abastecimiento de un ingenio azucarero (Martínez 1972).

$$\% \text{ Infestación} = \frac{\text{infestación de todas las muestras}}{\text{Total de las muestras}} \times 100.$$

El muestreo fue como sigue:

- Para aproximadamente 250 hectáreas de caña de azúcar se seleccionó un campo. Los campos fueron de tamaños variables, algunos mayores de 8 Has. En total se tomaron 40 campos.*
- En cada campo, se tomaron 5 lugares.*
- En cada lugar, se cortaron 20 cañas completas, se eliminaron las hojas y se contó el número total de entrenudos y también los entrenudos dañados exteriormente.*

Con los datos de los grados de infestación debido al barrenador se obtuvo la tabla 5.20.

Tabla 5.20: Análisis de varianza para el conjunto de datos del % de infestación

Causas de variación	gl	SC	CM
Entre campos	39	486684.12	12479.08
Lugares dentro de campos	4(40)= 160	210644.80	1316.53
Cañas dentro de lugares	19(5)40= 3800	658350.00	173.25
Total	3999		

A partir de los resultados de la tabla 5.20, se encontraron las estimaciones asociadas con las diferentes componentes de varianza del modelo como sigue

$$\begin{aligned}\hat{\sigma}_\epsilon^2 &= 173.25 \\ \hat{\sigma}_s^2 &= \frac{1316.53 - 173.25}{20} = 57.16 \\ \hat{\sigma}_c^2 &= \frac{12479.08 - 1316.53}{100} = 111.63 \\ \hat{V}(\bar{y}_{...}) &= \frac{111.63}{t} + \frac{57.16}{tr} + \frac{173.25}{trn}.\end{aligned}$$

Al suponer que $C_1 = 5C_2$ y $C_2 = 15C_3$, se estima que $r = 2$, $n = 5$ y $t = \frac{C_0}{190C_3}$.

La muestra más eficiente dependerá del costo total de muestrear 2 lugares por campo, tomando 5 cañas por lugar. Con los datos originales, se encuentra $\hat{V}(\bar{y}_{...}) = 3.12$, y teniendo en cuenta los estimadores de varianza, la muestra económica igualmente eficiente a la tomada originalmente consiste en seleccionar $n = 5$ cañas, $r = 2$ lugares por campo y $t = 51$ campos. Se requieren 510 cañas que van a dar la misma precisión del grado de infestación del barrenador que las 4000 cañas seleccionadas inicialmente.

5.11. Implementación en SAS

El programa en el paquete estadístico SAS a través del cual se obtuvieron los resultados expuestos en el conjunto de datos de los ejemplos 5.1 y 5.5 es el siguiente:

```
/* Diseño completamente aleatorizado de efectos fijos */

DATA EJEMPL051; /*archivo del ejemplo 5.1*/
INPUT DIETA REPLICA DIFPESO @@;
CARDS;
  1 1 -9.3 2 1 -10.1 3 1 1.5 4 1 -3.2
  1 2 2.5 2 2 -5.0 3 2 -2.0 4 2 -5.6
  1 3 -5.4 2 3 -7.2 3 3 -0.5 4 3 -8.4
  1 4 -3.6 2 4 -9.2 3 4 3.4 4 4 -5.3
  1 5 1.7 2 5 -8.1 3 5 -2.5 4 5 -1.4
;

PROC GLM DATA=EJEMPL051;
CLASS DIETA;
MODEL DIFPESO=DIETA;

/* Diseño completamente aleatorizado de efectos aleatorios */
DATA EJEMPL055;
INPUT REPLICACION MACHO PESO @@;
CARDS;
  1 85 61 1 113 75 1 134 58 1 158 57 1 165 59
  2 85 71 2 113 102 2 134 60 2 158 121 2 165 46
  3 85 56 3 113 95 3 134 59 3 158 56 3 165 120
  4 85 75 4 113 103 4 134 65 4 158 58 4 165 115
  5 85 99 5 113 98 5 134 54 5 158 101 5 165 93
  6 85 80 6 113 115 6 134 57 6 158 110 6 165 105
  7 85 75 7 158 67 7 165 75
  8 85 62 8 165 115
;
PROC PRINT DATA=EJEMPL055;

/* Obtención del análisis de varianza */
PROC GLM DATA=EJEMPL055;
CLASS MACHO;
MODEL PESO=MACHO;
RANDOM MACHO/TEST;

/*A través de la opción TEST se obtienen las pruebas estadísticas
correctas*/
/* Estimación de las componentes de varianza a través del método TYPE1
de Henderson */
PROC VARCOMP DATA=EJEMPL055 METHOD=TYPE1;
```

```

CLASS MACHO;
MODEL PESO=MACHO;
RUN;

```

5.12. Implementación en R

El programa en el software estadístico R a través del cual se obtuvieron los resultados expuestos en el conjunto de datos de los ejemplos [5.1](#), [5.5](#) y [5.7](#) es el siguiente:

```

#####
## Ejemplos 5.1 y 5.2 ##
#####

#Introducción de los datos del ejemplo
ejemplo5.1 <- data.frame(dieta=factor(rep(seq(1,4),5)),
  replica=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4),rep(5,4))),
  difpeso=c(-9.3,-10.1,1.5,-3.2,2.5,-5.0,-2.0,-5.6,-5.4,-7.2,-0.5,-8.4,-3.6,
    -9.2,3.4,-5.3,1.7,-8.1,-2.5,-1.4))

contr.sum(levels(ejemplo5.1$dieta)) ## Verifica la matriz de contrastes
anova5.1<-lm(difpeso~dieta,contrasts=list(dieta="contr.sum"),
  data=ejemplo5.1)
summary(anova5.1)
summary(aov(anova5.1))
# Estimación de medias
tabla.medias <- model.tables(anova5.1, type = "mean")
# Estimación de media general
media.dietas <- mean(tabla.medias$tables$dieta)
# Efectos de tratamientos
tabla.medias$tables$dieta - tabla.medias$tables$'Grand mean'

# Contrastes entre dietas
# Test de Bonferroni, valor p para los contrastes
pairwise.t.test(ejemplo5.1$difpeso,ejemplo5.1$dieta, p.adj = "bonf")

plot(difpeso~dieta,main="Distribución de DIFPESO",col="lightblue",
  data=ejemplo5.1)
abline(h=seq(-10,0,5),col=4,lty=2)
text(4,3,'F Value = 5.335')
text(4,2.5,'Prob > 0.0097')

#####
### Ejemplo 5.3 ###
#####

# prueba diferencia mínima significativa de Fisher LSD

```

```

# número de observaciones de la dieta tres "D3"
n1<-sum(ejemplo5.1$dieta=="3")
# número de observaciones de la dieta cuatro "D4"
n2<-sum(ejemplo5.1$dieta=="4")
# desviación estándar
s<-sqrt(sum((anova5.1$residuals)^2)/anova5.1$df.residual)
# cuadrado medio del error
CME<-s^2
# grados de libertad residuales
anova5.1$df.residual
# estimación de medias
tabla.medias <- model.tables(aov(anova5.1), type = "mean")
tc <- (-0.02+4.78)/sqrt((2*CME)/n1)
# valor crítico de la t alfa=0.10
tcrit<- qt(0.05,anova5.1$df.residual,lower.tail=F)
# valor de la diferencia mínima significativa
LSD<- tcrit*s*sqrt(1/n1+1/n2)
# límite inferior del intervalo
LI<-(-0.02+4.78)-LSD
# límite superior del intervalo
LS<-(-0.02+4.78)+LSD

#####
### Ejemplo 5.5 ###
#####

ejemplo5.5 <- data.frame(replicacion=factor(c(seq(1,8),seq(1,6),seq(1,6),
seq(1,7),seq(1,8))),macho=factor(c(rep(85,8),rep(113,6),rep(134,6),
rep(158,7),rep(165,8))), peso=c(61,71,56,75,99,80,75,62,75,102,95,103,
98,115,58,60,59,65,54,57,57,121,56,58,101,110,67,59,46,120,115,93,105,
75,115))

anova5.5 <- aov(peso ~ macho,data=ejemplo5.5)
summary(anova5.5)

plot(peso~macho,main="Distribución de Peso",col="lightblue",
data=ejemplo5.5)
abline(h=seq(40,120,20),col=4,lty=2)
text(85,120,'F Value = 1.78')
text(85,119.5,'Prob > F 0.1580')
# librería para el modelo II de efectos aleatorios
library(nlme)
# Modelo de efectos aleatorios, estimación por ML
data.lme1 <- lme(peso~1, random=~1 |macho, method="ML",data=ejemplo5.5)
# Estimación de las componentes de varianza por ML balanceado
VarCorr(data.lme1)
intervals(data.lme1)
# Modelo de efectos aleatorios, estimación por REML
data.lme2 <- lme(peso~1, random=~1 |macho, method="REML",data=ejemplo5.5)

```



```

# Estimación de las componentes de varianza por REML balanceado
VarCorr(data.lme2)
intervals(data.lme2)

# Estimación de la varianza del error
CME<-(sum((anova5.5$residuals)^2)/anova5.5$df.residual)
n<-sum(ejemplo5.5$macho=="85",ejemplo5.5$macho=="113",
ejemplo5.5$macho=="134",ejemplo5.5$macho=="158",ejemplo5.5$macho=="165")
# número de observaciones del tratamiento 85
r1<-sum(ejemplo5.5$macho=="85")
# número de observaciones del tratamiento 113
r2<-sum(ejemplo5.5$macho=="113")
# número de observaciones del tratamiento 134
r3<-sum(ejemplo5.5$macho=="134")
# número de observaciones del tratamiento 158
r4<-sum(ejemplo5.5$macho=="158")
# número de observaciones del tratamiento 165
r5<-sum(ejemplo5.5$macho=="165")
r0<-(n-sum(r1^2,r2^2,r3^2,r4^2,r5^2)/n)/4
# varianza del factor A (macho) desbalanceado
varmacho<-(1517.6-CME)/r0
vary <-CME+varmacho
# coeficiente de correlación intraclase de los machos
rho1<-varmacho/vary
# coeficiente de correlación intraclase de los terneros
rho2<-cme/vary

#####
### Ejemplo 5.7 ##
#####

ejemplo5.7 <- data.frame(replicacion=factor(c(seq(1,5),seq(1,4),seq(1,4))),
dieta=factor(c(rep(1,5),rep(2,4),rep(3,4))), colesterol=c(172,169,180,172,
178,175,164,150,161,160,160,150,148))

# Prueba de Kruskal-Wallis
moddca<-kruskal.test(ejemplo5.7$colesterol,ejemplo5.7$dieta)
moddca

# comparaciones múltiples no paramétricas
library(pgirmess)
kruskalmc(ejemplo5.7$colesterol,ejemplo5.7$dieta)

#####
### Ejemplo 5.8 ##
#####

library(pwr)      # pwr.anova.test
# k: número de tratamientos, n: número de replicas, f=phi/sqrt(n)

```

```

# con esta función se averigua la potencia para un k y un n dados
pwr.anova.test(k=4,n=5,f=2/sqrt(5),sig.level=0.05)
# con esta función se averigua el n para una potencia dada
pwr.anova.test(f=2/sqrt(5),k=4,power=0.80,sig.level=0.05)

phi <- seq(0, 4, 0.01)
pot <- pwr.anova.test(k = 4, n = 5, f = phi/sqrt(5), sig.level = 0.05,
power = NULL)$power
beta=1-pot
# Curva característica de operación
plot(phi,beta,type='l')
abline(v=2,lty=2)

#####
### Ejemplo 5.9 ##
#####

# Se encuentra f y después phi
pwr.anova.test(k=4,n=15,power=0.80,sig.level=0.05)
phi <- 0.4414577*sqrt(15)
phi

# phi^2=0.1086r
r <- phi^2/0.1086
pwr.anova.test(k=4,n=round(r),f=sqrt(0.1086),sig.level=0.05) # r=27
pwr.anova.test(k=4,f=sqrt(0.1086),power=0.80,sig.level=0.05) # r=27

#####
### Ejemplo 5.10 ##
#####

# Delta*=0.75, 1.0, 1.25, phi=Delta*^2*r/(2t)
phi1 <- c(0.75,1,1.25)/sqrt(2*4)

# 1-beta=0.70
pwr.anova.test(k=4,f=phi1[1],power=0.7,sig.level=0.05)
pwr.anova.test(k=4,f=phi1[2],power=0.7,sig.level=0.05)
pwr.anova.test(k=4,f=phi1[3],power=0.7,sig.level=0.05)

# 1-beta=0.80
pwr.anova.test(k=4,f=phi1[1],power=0.8,sig.level=0.05)
pwr.anova.test(k=4,f=phi1[2],power=0.8,sig.level=0.05)
pwr.anova.test(k=4,f=phi1[3],power=0.8,sig.level=0.05)
# 1-beta=0.90
pwr.anova.test(k=4,f=phi1[1],power=0.9,sig.level=0.05)
pwr.anova.test(k=4,f=phi1[2],power=0.9,sig.level=0.05)
pwr.anova.test(k=4,f=phi1[3],power=0.9,sig.level=0.05)

```

```
#####
# Curvas de operación para el modelo de efectos fijos #
#####

library(plotrix) # boxed.labels

nu1 <- 2 # a-1, a=3
a <- nu1+1
nu2 <- c(6,7,8,9,10,12,15,20,30,60,500) # a*(n-1)
n <- nu2/a+1
p <- c(seq(0.01,0.08,0.01),seq(0.1,0.8,0.1),1)

oldpar <- par(mar=c(4,4,5,2)+0.1,cex=0.8) # bottom, left, top, right
plot(c(1,6),c(1,0),ylim=c(0,1),type="n",axes=F,xlab="",
ylab = "Probabilidad de aceptación de las hipótesis",cex.lab=0.8)
# lines
for (i in p) segments(1,log10(i*100)/2,6,log10(i*100)/2,col='gray')
for (i in 1:6) segments(i,0,i,1,col='gray')

alpha <- 0.05
phi <- seq(1,4,0.01)
for (i in n) {
beta <- pwr.anova.test(k=a,n=i,f=phi/sqrt(i),sig.level=alpha,
power=NULL)$power
lines(phi,log10((1-beta)*100)/2,lwd=1.5,col="blue")
}
alpha <- 0.01
phi <- seq(1,5,0.01)
for (i in n) {
beta <- pwr.anova.test(k=a,n=i,f=phi/sqrt(i),sig.level=alpha,
power=NULL)$power
lines(phi+1,log10((1-beta)*100)/2,lwd=1.5,col="blue")
}
polygon(c(1,6,6,1),c(-0.3,-0.3,0,0),col="white",border=F)
# axis
axis(2,at=log10(p*100)/2,label=format(p,nsmall=2),las=1)
axis(1,at=1:6,label=c(1:3,expression(paste(Phi," (para ",
alpha == 0.05, ")"))), "", ""))
axis(3,at=1:6,label=c(expression(paste(Phi," (para ", alpha ==
0.01, ")"))), 1:5))
# lines
for(i in 0.01) segments(0,log10(i*100)/2,6,log10(i*100)/2,col="gray")

# title("Curvas características de operación para el análisis de varianza
# del modelo con efectos fijos", line = 3)
# labels
text(1.5,0.97,expression(nu[1]==2))
text(1.5,0.55,expression(alpha==0.05))
text(4.5,0.68,expression(alpha==0.01))
```

```

# arrows
arrows(3.05,0.33,5.21,0.33,length=0.1,code=3) # 6
arrows(2.85,0.365,4.83,0.365,length=0.1,code=3) # 7
arrows(2.708,0.4,4.56,0.4,length=0.1,code=3) # 8
arrows(2.58,0.435,4.35,0.435,length=0.1,code=3) # 9
arrows(2.461,0.47,4.18,0.47,length=0.1,code=3) # 10
arrows(2.33,0.505,3.96,0.505,length=0.1,code=3) # 12
arrows(2.21,0.54,3.76,0.54,length=0.1,code=3) # 15
arrows(2.09,0.575,3.58,0.575,length=0.1,code=3) # 20
arrows(1.97,0.61,3.41,0.61,length=0.1,code=3) # 30
arrows(1.85,0.645,3.245,0.645,length=0.1,code=3) # 60
arrows(1.74,0.68,3.1,0.68,length=0.1,code=3) # infity
# labels
boxed.labels(3.45,0.33,expression(nu[2]==6),bg="white",border=F,cex=0.8)
s <- 3.35
r <- 0.365
for (i in nu2[2:10]) {
  boxed.labels(s, r, i, bg = "white", border = F, cex = 0.8)
  s <- s - 0.07
  r <- r + 0.035
}
boxed.labels(s, 0.68, expression(infinity), bg = "white", border = F,
cex = 1)
par(oldpar)

#####
# Curvas de operación para el modelo de efectos aleatorios #
#####

nu1 <- 2 # a-1, a=3
a <- nu1+1
nu2 <- c(6,7,8,9,10,12,15,20,30,60,500) # a*(n-1)
#n <- nu2/a+1
p <- c(seq(0.01,0.08,0.01),seq(0.1,0.8,0.1),1)

oldpar <- par(mar=c(4,4,5,2)+0.1,cex=0.8) # bottom, left, top, right
plot(c(1,29),c(1,0),ylim=c(0,1),type="n",axes=F,xlab="",
ylab="Probabilidad de aceptación de las hipótesis",cex.lab=0.8)

for (i in p) segments(1,log10(i*100)/2,29,log10(i*100)/2,col="gray")
for (i in seq(1,30,2)) segments(i,0,i,1,col="gray")

alpha <- 0.05
lambda <- seq(1, 25, 0.1)
for (i in 1:11){
  power=pf(qf(alpha,a-1,nu2[i],lower.tail=FALSE,log.p=FALSE)/(lambda^2),a-1,
  nu2[i], lower.tail=FALSE,log.p=FALSE)
  lines(lambda,log10((1-power)*100)/2,lwd=1.5,col="blue")
}

```

```

alpha <- 0.01
lambda <- seq(1,25,0.1)
for (i in 1:11){
power=pf(qf(alpha,a-1,nu2[i],lower.tail=FALSE,log.p=FALSE)/(lambda^2),a-1,
nu2[i],lower.tail=FALSE,log.p=FALSE)
lines(lambda+4,log10((1-power)*100)/2,lwd=1.5,col="blue")
}
polygon(c(1,29,29,1),c(-0.3,-0.3,0,0),col="white",border=F)
# axis
axis(2,at=log10(p*100)/2,label=format(p,nsml=2),las=1)
axis(1,at=seq(1,29,2),label=c(seq(1,24,2),expression(paste(lambda," (para ",
alpha == 0.05, ")")), "", ""))
axis(3,at=seq(3,29,2),label=c(expression(paste(lambda," (para ", alpha ==
0.01, ")")), seq(1, 26, 2)))
# lines
for (i in 0.01) segments(1,log10(i*100)/2,29,log10(i*100)/2,col="gray")

# title("Curvas características de operación para el análisis de varianza
# del modelo con efectos aleatorios",line = 3)
# labels
text(2.2,0.97,expression(nu[1]==2))
text(2.1,0.55,expression(alpha==0.05))
text(13.9,0.68,expression(alpha==0.01))
# arrows
arrows(10.44,0.33,19.2,0.33,length=0.1,code=3) # 6
arrows(9.24,0.365,17.05,0.365,length=0.1,code=3) # 7
arrows(8.24,0.4,15.46,0.4,length=0.1,code=3) # 8
arrows(7.4,0.435,14.2,0.435,length=0.1,code=3) # 9
arrows(6.74,0.465,13.2,0.465,length=0.1,code=3) # 10
arrows(5.93,0.505,12,0.505,length=0.1,code=3) # 12
arrows(5.32,0.54,11.01,0.54,length=0.1,code=3) # 15
arrows(4.76,0.575,10.2,0.575,length=0.1,code=3) # 20
arrows(4.22,0.61,9.4,0.61,length=0.1,code=3) # 30
arrows(3.8,0.645,8.78,0.645,length=0.1,code=3) # 60
arrows(3.4,0.68,8.22,0.68,length=0.1,code=3) # infity
# labels
boxed.labels(12.5,0.33,expression(nu[2]==6),bg="white",border=F,cex=0.8)
s <- 11.8
r <- 0.365
for (i in nu2[2:5]) {
boxed.labels(s,r,i,bg="white",border=F,cex=0.8)
s <- s-0.8
r <- r+0.035 }
s <- 8.8
for (i in nu2[6:10]) {
boxed.labels(s,r,i,bg="white",border=F,cex=0.8)
s <- s-0.5
r <- r+0.035
}

```

```
boxed.labels(s,0.68,expression(infinity),bg="white",border=F,cex=1)
par(oldpar)
```

5.13. Ejercicios

1. Considere el siguiente arreglo de efectos de tratamientos (Iemma 1993):

α_1	α_2	α_3
5	6	9
4	7	7
3	8	11
4	8	12

Caracterizándose el modelo: $Y = X\theta + e$:

- Obtenga tres soluciones al sistema, o sea, θ_1^0 , θ_2^0 y θ_3^0 , y verifique numéricamente la invarianza de la estimación, es decir, verifique $\hat{Y} = X\theta_i^0$, $i = 1, 2, 3$.
- Complete la siguiente tabla de ANOVA:

C de V	gl	SC	CM	F
Media	$\text{ran}(P_1)$	$Y^t P_1 Y$		
Tratamiento	$\text{ran}(P_{12} - P_1)$	$Y^t (P_{12} - P_1) Y$		
Parámetros	$\text{ran}(P_{12})$	$Y^t P_{12} Y$		
Residuo	$\text{ran}(I - P_{12})$	$Y^t (I - P_{12}) Y$		
Total	$\text{ran}(I)$	$Y^t Y$		

- Considere una extensión del arreglo anterior teniendo en cuenta el modelo: $y_{ij} = \mu + \alpha_i + e_{ij}$, $i = 1, 2, \dots, a$, $j = 1, 2, \dots, n_i$.
 - Obtenga X , $X^t X$ y $X^t Y$.
 - Considere el vector $\lambda^t = (0, n_1, n_2, \dots, n_a)$, obtenga la matriz $X^t X + \lambda \lambda^t$ en términos de n y de n_i ($n = \sum n_i$).
 - Verifique que

$$(X^t X + \lambda \lambda^t)^{-1} = \begin{bmatrix} \frac{n+1}{n^2} & -\frac{1}{n^2} & \dots & -\frac{1}{n^2} \\ -\frac{1}{n^2} & \frac{1}{n_1} - \alpha & \dots & -\alpha \\ \vdots & \vdots & \ddots & \vdots \\ -\frac{1}{n^2} & -\alpha & \dots & \frac{1}{n_a} - \alpha \end{bmatrix},$$

donde $\alpha = \frac{n-1}{n^2}$.

iv. Construya la matriz

$$\begin{bmatrix} \mathbf{X}^t \mathbf{X} & \lambda \\ \lambda^t & \phi \end{bmatrix} \text{ y } \begin{bmatrix} \mathbf{X}^t \mathbf{X} & \lambda \\ \lambda^t & \phi \end{bmatrix}^{-1}$$

v. Determine $\boldsymbol{\theta}_4^0 = (\mathbf{X}^t \mathbf{X} + \lambda \lambda^t)^{-1} \mathbf{X}^t \mathbf{Y}$ y $\hat{\mathbf{Y}} = \mathbf{X} \boldsymbol{\theta}_4^0$

$$\boldsymbol{\theta}_5^0 = \begin{bmatrix} \mathbf{X}^t \mathbf{X} & \lambda \\ \lambda^t & \phi \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{X}^t \mathbf{Y} \\ \boldsymbol{\theta} \end{bmatrix}, \quad \hat{\mathbf{Y}} = \mathbf{X} \boldsymbol{\theta}_5^0.$$

2. Suponga que se tienen r réplicas de un experimento con dos factores de orden $a \times b$. Considere la descomposición de las observaciones de acuerdo con:

$$\sum_{ijk} (y_{ijk} - \bar{y}_{...})^2 = \sum_{ijk} [(\bar{y}_{i..} - \bar{y}_{...}) + (\bar{y}_{.j.} - \bar{y}_{...}) + (y_{ijk} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...})]^2.$$

- Muestre que en ese arreglo los valores de cualquier término del lado derecho de esa ecuación son ortogonales a cualquiera de los otros arreglos. Con base en el resultado muestre que: $SCTotal = SCA + SCB + SCError$.
- Muestre que: $E(\bar{y}_{i..} - \bar{y}_{...}) = \alpha_i$ y $E(\bar{y}_{.j.} - \bar{y}_{...}) = \beta_j$.
- Halle: $Var(\bar{y}_{i..} - \bar{y}_{...})$ y $Var(\bar{y}_{.j.} - \bar{y}_{...})$.

3. Considere el siguiente conjunto de datos relacionados con tres tratamientos

T_1	T_2	T_3
8	4	8
6	12	18
5	8	
2		
9		

- Calcule el estadístico F para probar cada una de las siguientes hipótesis:

$$H_0^{(1)} : \begin{cases} \mu_1 - \mu_2 = 0 \\ \mu_1 + \mu_2 - 2\mu_3 = 0 \end{cases}$$

$$H_0^{(2)} : \begin{cases} \mu_1 - \mu_3 = 0 \\ 3\mu_1 + 2\mu_2 - 5\mu_3 = 0. \end{cases}$$

- Construya la base de las funciones estimables.

- c. Construya los posibles contrastes ortogonales, diga si son MELIS y obtenga la varianza de estos.

4. Muestre que cuando se tienen a tratamientos (Searle 1987):

- a. Puede obtenerse el conjunto de contrastes a partir de la expresión general

$$\gamma_i = \sum_{h=1}^{i-1} \mu_h - (i-1)\mu_i \quad \text{para } i = 2, 3, \dots, a.$$

- b. Construya el estadístico de prueba para la hipótesis $H_0 : \gamma_i = 0$.
c. Demuestre que, en el caso de una vía de clasificación con r réplicas,

$$\sum_{i=2}^a \frac{\hat{\gamma}_i^2}{\frac{Var(\hat{\gamma}_i)}{\sigma^2}} = r \sum_{i=1}^a (\bar{y}_{i.} - \bar{y}_{..}).$$

Deduzca, en cada caso, quién es $\hat{\gamma}_i$ y $V(\hat{\gamma}_i)$.

- d. Muestre que $Cov[MELI(\gamma_i), MELI(\gamma_{i'})] = 0$, para $i \neq i'$.

5. Si $E(Y_{ij}) = \mu + \alpha_i$ $i = 1, \dots, m$ $j = 1, \dots, k$, $Var(Y_{ij}) = \sigma^2$:

- a. Escriba el modelo en forma matricial.
b. Obtenga el $MELI(\alpha_i - \bar{\alpha})$.
c. Obtenga $V(MELI(\alpha_i - \bar{\alpha}))$.
d. Si $\sum a_i = 0$, obtenga $MELI(\sum a_i \alpha_i)$ y $V(MELI(\sum a_i \alpha_i))$.
e. Encuentre $Cov[MELI(\alpha_1 - \bar{\alpha}), MELI(\alpha_2 - \bar{\alpha})]$.

6. Considere el siguiente conjunto de tratamientos en un ensayo DCA.

Tratamiento 1	Tratamiento 2	Tratamiento 3
19	16	13
18	11	16
21	13	18
18	14	11
	11	15
		11

- a. Verifique que $\sum_{i=1}^t n_i (\bar{y}_{i.} - \bar{y}_{..}) = 0$.
b. Calcule las sumas de cuadrados y construya la tabla de ANOVA. Comente en detalle los resultados obtenidos.

7. Considere la siguiente información relacionada con tres tratamientos en un DCA.

$T1$	$T2$	$T3$
$\bar{y}_1 = 81.06$	$\bar{y}_2 = 78.56$	$\bar{y}_3 = 81.87$
$S_1 = 17.05$	$S_2 = 15.43$	$S_3 = 14.36$
$n_1 = 32$	$n_2 = 16$	$n_3 = 16$

- Presente la tabla de ANOVA para este ensayo e interprete los resultados.
- Calcule intervalos de confianza simultáneos para las diferencias de medias.

8. Dada la siguiente tabla de ANOVA

Causas variación	gl	SC	E(CM)
Entre tratamientos	4	244	$\sigma^2 + \frac{7}{4} \sum_{i=1}^t \tau_i^2$
Entre U.E. dentro de tratamientos	30	270	σ^2

- Escriba el modelo apropiado.
 - Fije la hipótesis nula tanto simbólicamente como en palabras. Proponga el experimento que fue diseñado “probablemente” para juzgar esta hipótesis.
 - Juzgue la hipótesis nula planteada en b.
9. En un estudio sobre el efecto del origen del polen, el contenido proteico del maíz fue medido. Un tipo de maíz con índice proteico bajo (origen de la mazorca) se poliniza con una clase de índice proteico alto y con otra clase de bajo. Las medidas registradas en la siguiente tabla son el porcentaje proteico. Se hicieron las determinaciones del origen de cada mazorca y del polen (Martínez 1981).

Mazorca	Proteína			
	Alta		Baja	
1	11.44	11.18	11.22	11.00
2	10.12	9.78	9.54	9.42
3	10.59	10.64	9.98	10.08
4	11.55	11.39	10.67	10.87
5	9.90	9.85	10.06	10.21
6	12.29	12.45	12.10	11.89
7	10.88	11.30	11.26	10.83
8	9.57	9.74	9.44	9.61

- a. Describa los niveles, las unidades experimentales, la variable respuesta y una aleatorización correcta para este diseño.
 - b. Especifique el diseño y el modelo para analizar estos datos.
 - c. Efectúe el ANOVA correspondiente al modelo e interprete la prueba F .
 - d. Estime e interprete las componentes de varianza.
 - e. Compare la pérdida promedio entre proteína alta y baja.
 - f. Obtenga un intervalo de confianza del 90 % para la diferencia entre proteína alta y baja.
 - g. Calcule el número de réplicas para un experimento similar suponiendo una potencia de 0.90.
10. Retome el ejercicio 5 del capítulo 1. Los datos observados para dicho problema se presentan a continuación:

Icopor	Biopak	Cry-0-Vac	Shopak
5.33	6.59	4.95	2.41
4.95	7.90	4.44	2.83
5.10	4.48	3.48	2.93
7.14	7.32	3.92	2.38
7.84	6.41	8.62	2.11

- a. Describa los factores, los niveles, las unidades experimentales, la variable respuesta y una aleatorización correcta para este diseño.
 - b. Especifique el diseño y el modelo para analizar estos datos.
 - c. Efectúe el ANOVA correspondiente al modelo e interprete la prueba F .
 - d. Calcule un intervalo de confianza del 95 % para la pérdida promedio de peso con la envoltura Shopak.
 - e. Compare la pérdida promedio de peso entre Icopor y Biopak.
 - f. Calcule el número de réplicas para un experimento similar suponiendo una potencia de 0.80.
11. Retome el ejercicio 6 del capítulo 1. Los datos siguientes (en cm) representan parte de los datos obtenidos por las investigadoras.

Fondo arenoso	Manglar	Pasto marino
4.09	3.80	3.78
4.14	3.96	4.19
3.85	4.05	4.27
4.04	3.47	3.65
3.21	3.89	3.99
4.27	3.46	3.61
3.81	3.94	3.55
4.02	3.58	3.41
3.08	4.03	3.82
4.72	3.68	4.11
4.03	3.76	3.60
4.07	3.91	3.90
3.83	3.32	3.99
	4.21	3.94
	3.86	3.35
	4.02	

- a. Establezca el modelo lineal, efectúe el ANOVA correspondiente para estos datos e interprete los resultados.
 - b. Establezca un intervalo de confianza del 95 % para la diferencia de medias entre fondo arenoso y manglar.
12. Se midió la concentración de calcio en hojas de una especie de árbol, se tomaron aleatoriamente cuatro hojas y se hicieron cuatro lecturas de cada hoja lográndose los siguientes resultados en porcentaje de peso seco:

Hojas	Lecturas			
1	3.28	3.09	3.03	3.03
2	3.52	3.48	3.38	3.38
3	2.88	2.80	2.81	2.76
4	3.34	3.38	3.23	3.26

- a. Haga una descripción completa del experimento especificando: objetivos, población, factores, unidades experimentales y variables respuesta.
- b. Indique un método de aleatorización apropiado para el experimento.
- c. Establezca el modelo para analizar estos datos y presente la tabla de ANOVA correspondiente.
- d. Enuncie las hipótesis estadísticas del problema.
- e. Estime los porcentajes de variación entre hojas y lecturas.

- f. Calcule un intervalo de confianza del 95 % para la concentración promedio de calcio por hoja.
- g. Estime el número de réplicas necesarias para alcanzar una potencia del 85 %. Discuta la conveniencia de aumentar hojas en vez de réplicas o lecturas.
13. Se estudió los hábitos alimenticios de *M. Ocellata* como depredador de larvas de *C. quinquefasciatus*. En particular, se comparó el consumo promedio diario de larvas en los últimos 5 instares del depredador. Una parte de los resultados obtenidos es la siguiente:

Instares				
7	8	9	10	11
25.16	24.22	27.56	25.58	24.20
20.85	27.75	27.10	23.67	23.95
20.00	25.14	26.64	24.73	25.65
20.67	29.25	26.63	25.30	24.95
18.67	25.25	29.38	22.75	25.65
20.33	27.40	28.00	24.18	24.26
19.00	24.60	28.25	26.50	25.38
21.33	25.60	27.67	25.36	24.94
17.00		26.90	27.08	23.61
21.50		27.56	23.42	23.72
		28.89	24.85	22.71
		24.10	21.09	
		25.56		
		28.33		
		27.50		

- a. Presente el modelo para analizar este conjunto de datos y la base de funciones estimables.
- b. Lleve a cabo el ANOVA e interprete los resultados.
- c. Estime el consumo promedio en cada instar.
- d. Compare el consumo promedio de los instares séptimo y undécimo.
14. Se comparó la población de aves en cuatro áreas de bosques diferentes: un rodal de ciprés (RC), un bosque secundario al noroeste (BSN), una plantación de pinos patula (PP) y un bosque secundario aislado (BSA), localizadas en Piedras Blancas (Antioquía, Colombia). El total de especies observadas por día fue el siguiente:

RC	BSN	EP	BSA
4	10	1	8
2	10	1	9
5	12	2	9
2	11	3	5
2	10	1	7
1	12	1	8
2	14	-	7
3	12	2	4
2	14	2	12
4	11	3	9

- a. Especifique el modelo, construya la tabla ANOVA e interprete los resultados.
- b. Estime las medias para cada uno de los bosques y construya los intervalos de confianza respectivos fijando un $(1 - \alpha) \times 100$ apropiado.
15. Se realizó un estudio piloto para determinar la variabilidad en la tasa de sedimentación de eritrocitos en infantes de un día de nacidos. De cada niño elegido aleatoriamente entre los recién nacidos, se tomaron varias muestras que se entregaron a diferentes laboratoristas para su análisis. Se tienen los siguientes resultados:

Muestras	Infantes							
	1	2	3	4	5	6	7	8
1	110	130	50	130	45	120	100	130
2	90	115	75	45	55	50	200	80
3	120	105	85	50	65	150	90	70
4			40	40			70	80
5							90	150

- a. Construya la tabla ANOVA e interprete los resultados.
- b. Calcule un intervalo del 95 % de confiabilidad para la varianza entre infantes. Discutir el intervalo obtenido.
- c. Estime la variabilidad entre laboratoristas y el porcentaje de la variabilidad total.
16. Un grupo de ratones con carcinomas mamarios fue tratado por irradiación. Después del tratamiento, se tomaron biopsias del tumor y se realizaron varios recuentos mitóticos (CPM) con los siguientes resultados (Gill 1978):

Conteos	Ratones									
	1	2	3	4	5	6	7	8	9	10
1	21	68	50	11	1	26	12	47	36	31
2	19	73	52	10	12	15	12	47	31	27
3	26	70	59	12	11	11	9	40	42	24
4		60	48	11			15	42		

- Establezca el modelo, realice el ANOVA correspondiente e interprete los resultados.
 - Estime las componentes de varianza.
 - Al repetir el experimento cambiando la dosis de irradiación, ¿se aconseja aumentar unidades experimentales o recuentos mitóticos? Teniendo en cuenta este experimento, diferenciar las fuentes de variación y explicar el origen de cada una de ellas.
17. Las isletas beta de Langerhans son las células productoras de insulina en el páncreas. Los siguientes datos representan la producción de insulina por isletas del páncreas de ratas obesas en un período de tres semanas. Inicialmente se prepararon 36 cultivos y semanalmente se tomaron 9 para calcular la cantidad de insulina producida (Koopmans y Sclafani 1981).

	Semana			
	0	1	2	3
	31.2	18.4	55.2	69.2
	72.0	37.2	70.4	52.0
	31.2	24.0	40.0	42.8
	28.2	20.0	42.8	40.6
	26.4	20.6	36.8	31.6
	40.2	32.2	80.4	66.4
	27.2	23.0	60.4	62.0
	33.4	22.2	65.6	59.2
	17.6	7.8	15.8	22.4

- Construya un diagrama de cajas para cada semana y analice variabilidad y tendencia en la producción de insulina con el tiempo.
 - Realice el ANOVA para estos datos. ¿A qué conclusión puede llegar?
 - Obtenga el tamaño de muestra apropiado si se desea alcanzar una potencia de al menos un 70 %.
18. Se conjetura que el peso al nacer de un niño está asociado con el nivel de consumo de cigarrillos de la madre durante el primer trimestre del

embarazo. Un estudio realizado en una clínica de maternidad dio los siguientes resultados para madres agrupadas según el hábito de fumar. Los datos son los pesos (en gramos) de los niños al nacer (Rosner 2016).

No fumadoras	Exfumadoras	Fumadoras (< 1 paquete)	Fumadoras (≥ 1 paquete)
3400	2620	2670	2800
2800	3300	2800	3080
3120	3710	2630	2580
3350	3210	2130	2220
4170	3530	3760	2800
3760		3260	3200
3440		2800	2630
			2450

- Efectúe el ANOVA e interprete la prueba F .
 - Calcule medias y varianzas para cada grupo.
 - Compare el peso promedio de no fumadoras y de exfumadoras, use $\alpha = 0.025$.
 - Obtenga el tamaño de muestra apropiado si se desea alcanzar una potencia de al menos un 80 %.
19. Dada la siguiente información, complete la tabla de análisis de varianza y calcule los componentes de varianza. Suponga que los 7 tratamientos se escogieron aleatoriamente y se repitieron cuatro veces cada uno.

C de V	gl	SC	CM	E(CM)	F	Valor p
Tratamientos		5587174			9.83	<0.0001
Error						
Total						

$y_{..} = 57110$, $y_{1.} = 8507$, $y_{2.} = 10712$, $y_{3.} = 10207$, $y_{4.} = 8512$,
 $y_{5.} = 7184$, $y_{6.} = 6724$, $y_{7.} = 5264$.

- Escriba el modelo correspondiente, explique cada componente y escriba los supuestos.
- ¿Qué hipótesis se prueba con el anterior análisis? Pruebe la hipótesis planteada y estime las componentes de varianza.
- Obtenga el tamaño de muestra apropiado si se desea alcanzar una potencia de al menos un 85 %.

20. Los datos que se expresan a continuación corresponden a toneladas por hectárea de trigo (Bonza). El propósito fue evaluar 9 métodos de control de malezas. El número de réplicas fue de 3. El ensayo se realizó en Tangua (Nariño).

Material	Réplicas		
	I	II	III
Afalón-Pree	5.5	4.5	2.3
Afalón-Emer	4.8	3.9	4.2
Igram-50	4.7	4.2	3.5
Aretit-Pos-21	4.5	3.6	2.9
Aretit-Emer	4.6	4.9	4.1
Aretit-Pos-41	4.9	4.7	2.2
Banvel+Afalón	4.9	4.9	3.8
Banvel+Igram	4.7	4.1	3.3
Testigo	3.6	4.0	3.0

- Presente la tabla del análisis de varianza.
 - Estime el efecto promedio de cada matamaleza.
 - Concluya de acuerdo con los resultados de los numerales anteriores.
21. Escriba el modelo correspondiente a un diseño completamente al azar con submuestreo y explique cómo calcula las sumas de cuadrados para las diferentes fuentes de variación. Suponga igual número de réplicas y submuestras por tratamiento.
22. En un experimento de cítricos se aplicaron dos cantidades de nitrógeno (50 y 100) combinadas con dosis de potasio (100 y 200). Se planeó comparar: i) entre niveles de nitrógeno, ii) entre niveles de potasio y iii) interacción entre nitrógeno y potasio. Escriba los contrastes correspondientes a las comparaciones planeadas.
23. Un antropólogo está interesado en el estudio de las diferencias físicas que existen entre varias razas que habitan en Hawaii. Como parte del estudio se obtiene una muestra de nueve mujeres de cinco años de los tres grupos raciales (caucásica, china y japonesa) y se toma una serie de medidas antropométricas de cada niña. En el estudio se está interesado en determinar si la raza oriental difiere de la caucásica y si entre las razas orientales hay diferencias. Los resultados de las medias y varianzas fueron:

	Caucásica	Japonesa	China	Total
Medias	14.619	13.188	13.694	13.833
Varianzas	116.952	105.504	109.552	332.008

Para la igualdad de efectos de tratamientos, se obtuvo el valor de la $F = 23.04$.

- a. Presente el modelo apropiado para llevar a cabo el análisis de estos datos.
 - b. Construya la base de las funciones estimables.
 - c. Proponga dos funciones que siendo estimables son MELIS, así como sus varianzas y covarianzas.
 - d. Determine las pruebas pertinentes que lo lleven a concluir estadísticamente las inquietudes del antropólogo.
 - e. Si la medida asociada con la segunda replicación de la raza japonesa se perdió, proponga un estimador para ese valor faltante.
24. Suponga en el ejercicio anterior que en la lista hay p -razas y, por cuestiones del diseño, solamente se seleccionan r unidades experimentales, cada una con s submuestras.
- a. Proponga el modelo para llevar a cabo el análisis de esta información.
 - b. Muestre la tabla de análisis de varianza para este diseño.
 - c. Obtenga los estimadores apropiados para los componentes de varianza asociados con el modelo anterior.
 - d. Si se desea llevar a cabo la prueba de hipótesis

$$H_0 : \mu_i - \mu_{i'} = 0, \quad i \neq i',$$

¿cuál es el estadístico de prueba? Construya un intervalo de confianza tamaño $(1 - \alpha) \%$ para esta diferencia.

25. Considere el modelo asociado con un DCA, es decir,

$$y_{ij} = \mu + \alpha_i + \epsilon_{ij},$$

donde $i = 1, \dots, a$, $j = 1, \dots, n_i$, con $n_i > 0$ y $\epsilon_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$. Construya un intervalo tamaño $(1 - \alpha)$ para la siguiente función lineal paramétrica $\sum_{i=1}^t a_i \alpha_i$, con $\sum_{i=1}^t a_i = 0$. Justifique en detalle su respuesta.

26. Considere el modelo $E(Y_{ij}) = \mu + \alpha_i$, $i = 1, 2, \dots, m$, $j = 1, 2, \dots, k$, además se satisface que $Var(Y_{ij}) = \sigma^2$, $Cov(Y_{ij}, Y_{i'j'}) = 0$, $i \neq i'$, $j \neq j'$.

- a. Escriba el modelo en la forma $E(\mathbf{Y}) = \mathbf{X}\boldsymbol{\beta}$.
 - b. Escriba $\mathbf{X}^t\mathbf{Y}$ en función de $Y_{i.}$.
 - c. Si $\bar{\alpha}$ es dado por $\bar{\alpha} = \frac{1}{m} \sum \alpha_i$, obtenga las ecuaciones normales en función de $\mu, \bar{\alpha}, Y_{i.}$ y $Y_{..}$.
 - d. De las ecuaciones normales, obtenga $MELI(\alpha_i - \bar{\alpha})$ y escribálas en la forma $\mathbf{q}^t \mathbf{X}^t \mathbf{Y}$ y $\alpha_i - \bar{\alpha}$ como una combinación lineal de los parámetros.
 - e. Encuentre $V(MELI(\alpha_i - \bar{\alpha}))$.
 - f. Si $\sum a_i = 0$, encuentre el $MELI(\sum a_i \alpha_i)$ y su respectiva varianza.
 - g. Encuentre
 - i $COV(MELI(\alpha_i - \bar{\alpha}), MELI(\alpha_{i'} - \bar{\alpha}))$.
 - ii Si $\sum a_i^{(1)} = 0$ y $\sum a_i^{(2)} = 0$, encuentre $COV(MELI(\sum a_i^{(1)} \alpha_i), MELI(\sum a_i^{(2)} \alpha_i))$.
 - h. Encuentre $SC(MELI(\sum a_i \alpha_i)), SC(Y_{i.}/k)$ y $SC(Y_{..}/mk)$.
27. Hocking (1985) describe un experimento para comparar 5 fluidos seleccionados previamente en la producción de ácido láctico en corredores de largas distancias. Por razones no relacionadas con los fluidos, hay un número desigual de corredores asignados a cada tratamiento. Las medias y varianzas de las muestras y las frecuencias de celdas se muestran en la siguiente tabla:

	Fluido				
	1	2	3	4	5
$\bar{y}_{i.}$	33.3	32.6	30.9	29.0	26.1
s_i^2	13.1	14.2	12.2	13.9	14.2
n_i	10	7	10	8	6

- a. Complete la tabla de ANOVA probando la hipótesis de igualdad de medias.
- b. El fluido 1 era simplemente agua, los fluidos 2 y 3 son una bebida deportiva a una baja y alta concentración. Los fluidos 4 y 5 son otras bebidas deportivas en baja y alta concentración. Esta descripción sugiere los siguientes contrastes:

$$C_1 : \mu_1 - \frac{1}{4} \sum_{i=2}^5 \mu_i$$

$$C_2 : \frac{\mu_2 + \mu_3}{2} - \frac{\mu_4 + \mu_5}{2}$$

$$C_3 : \mu_2 - \mu_3$$

$$C_4 : \mu_4 - \mu_5$$

Desarrolle la suma de cuadrados para probar las hipótesis de interés, realice pruebas estadísticas usando el criterio de Scheffé y establezca claramente sus conclusiones.

Note que las sumas de cuadrados para estos contrastes no dan la suma de cuadrados de los tratamientos. ¿Por qué?

c. Reemplace C_1 y C_2 por:

$$C_5 : \mu_1 - \frac{1}{n - n_1} \sum_{i=2}^4 n_i \mu_i, \quad \text{con } n = \sum n_i$$

$$C_6 : \frac{n_2 \mu_2 + n_3 \mu_3}{n_2 + n_3} - \frac{n_4 \mu_4 + n_5 \mu_5}{n_4 + n_5}.$$

Pruebe las hipótesis asociadas como en la parte b., compare los resultados con los de C_1 y C_2 y verifique que C_3 , C_4 , C_5 y C_6 son contrastes ortogonales.

d. Dos contrastes de interés son:


$$C_7 : \frac{\mu_2 + \mu_4}{2} - \frac{\mu_3 + \mu_5}{2}$$

$$C_8 : \mu_3 - \mu_2 - \mu_5 + \mu_4.$$

Haga una descripción verbal de estos contrastes. Observe que C_8 puede ser visto como un contraste de interacción. Estos contrastes pueden ser usados en lugar de, o en adición a, C_3 y C_4 en el estudio inicial. El uso de más de $p - 1 = 4$ contrastes sugiere que el criterio t separado no es apropiado. Verifique que C_5 , C_6 , C_7 y C_8 forman un conjunto ortogonal.

28. Para un DCA con t tratamientos, r réplicas por tratamiento y n observaciones por unidad experimental, muestre que (Searle 1987):

$$Var \left(\sum c_i \bar{Y}_{i..} \right) = \sum c_i^2 \frac{\sigma^2 + n\sigma_\epsilon^2}{rn}.$$



Capítulo
seis

**Pruebas de
comparaciones
múltiples y
validación de
supuestos**

En este capítulo, se presentan diferentes pruebas de comparación múltiple con el fin de tomar decisiones una vez la hipótesis general sobre igualdad de tratamientos ha sido rechazada. Adicionalmente, se desarrolla un conjunto de técnicas a partir de las cuales se validan los supuestos básicos (homogeneidad de varianza, independencia, normalidad y aditividad) del ANOVA.

6.1. Pruebas de comparaciones múltiples

Siempre que los resultados del análisis de varianza conduzcan a rechazar la hipótesis nula de no diferencia entre las medias poblacionales surgirá la pregunta respecto a qué tratamiento es el “mejor”, lo cual es de interés en el caso de un modelo de efectos fijos como el presentado en (5.1). De hecho, lo que con frecuencia se desea saber, aunque no siempre, es qué grupos de tratamientos son iguales a través de la realización de una prueba en todas las comparaciones de cada uno de los pares de tratamientos. El experimentador debe tener precaución al pretender encontrar diferencias significativas entre las medias individuales, y siempre asegurarse que su procedimiento de comparación sea válido. Aunque la probabilidad α (fijada con anterioridad) de rechazar una hipótesis nula verdadera para la prueba como un todo es pequeña, la probabilidad de rechazar al menos una hipótesis verdadera cuando se prueban varios pares de medias es mayor que α .

6.1.1. Conceptos preliminares

Sea un experimento con t tratamientos y medias poblacionales $\mu_1, \mu_2, \dots, \mu_t$. Sea una combinación lineal de las medias $L = \sum_{i=1}^t a_i \mu_i$, tal que $\sum_{i=1}^t a_i = 0$, es decir, un contraste.

Sean $\bar{y}_1, \bar{y}_2, \dots, \bar{y}_t$ las medias muestrales obtenidas a partir de estas t muestras independientes de tamaños $n_1, n_2, \dots, n_t$, respectivamente. Sobre los supuestos de distribución normal de los residuos y varianzas iguales, se tiene que:

$$\text{i) } \hat{L} = \sum_{i=1}^t a_i \bar{y}_i, \text{ encontrándose además que } E(\hat{L}) = L.$$

$$\text{ii) } V(\hat{L}) = \sigma^2 \sum_{i=1}^t \frac{a_i^2}{n_i} \text{ y } \hat{V}(\hat{L}) = CME \sum_{i=1}^t \frac{a_i^2}{n_i}.$$

$$\text{iii) } \hat{L} \sim N(L, V(\hat{L})).$$

iv) Dos contrastes

$$L_1 = \sum_{i=1}^t a_{i1} \mu_i \quad \text{y} \quad L_2 = \sum_{i=1}^t a_{i2} \mu_i,$$

cuyos estimadores son $\hat{L}_1 = \sum_{i=1}^t a_{i1} \bar{y}_i$ y $\hat{L}_2 = \sum_{i=1}^t a_{i2} \bar{y}_i$, respectivamente.

Se dice que son ortogonales si la covarianza entre ellos es nula, es decir, si se satisface $\sum_{i=1}^t a_{i1} a_{i2} / n_i = 0$.

6.1.2. Procedimientos de comparaciones múltiples

Si el interés es comparar todas las parejas de las t medias de los tratamientos, es decir, se desea probar $H_0 : \mu_i = \mu_{i'}$ para toda $i \neq i'$, $i, i' = 1, \dots, t$. Existen en la literatura estadística muchos métodos que permiten hacer estas comparaciones; se destacan a continuación algunos de estos.

1. Prueba t de student

Suponga que se tiene interés en el contraste $L = \sum_{i=1}^t a_i \mu_i$. Teniendo en cuenta los grados de libertad del error (gle) y que $\frac{CME}{\sigma^2} \sim \chi_{(gle)}^2$ y, por la independencia de este con las $\bar{y}_i$, ($i = 1, \dots, t$), entonces,

$$\frac{\hat{L} - L}{\sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}}} \sim t_{(gle)}$$

De donde para un contraste particular:

$$Pr \left[\hat{L} - t_{(gle, \alpha/2)} \sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}} \leq L \leq \hat{L} + t_{(gle, \alpha/2)} \sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}} \right] = 1 - \alpha.$$

Si se tiene en cuenta en la hipótesis: $H_0 : L = 0$ se rechaza con un nivel de significación de α si

$$|\hat{L}| > t_{(gle, \alpha/2)} \sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}}$$

En caso contrario, se tendrá evidencia estadística para no rechazar la hipótesis de interés.

2. Método de Scheffé

Scheffé (1953) demuestra que para la totalidad de los contrastes L ,

$$P\left(\hat{L} - F_0 S_0 \leq L \leq \hat{L} + F_0 S_0\right) = 1 - \alpha,$$

donde

$$F_0 = \sqrt{(t-1)F_{(t-1, gle, \alpha)}} \quad y \quad S_0 = \sqrt{\hat{V}(\hat{L})} = \sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}}.$$

Si se plantea la hipótesis $H_0 : L = 0$, se rechaza a un nivel significación α si

$$|\hat{L}| \geq F_0 S_0.$$

Por otro lado, si L_1 y L_2 son contrastes ortogonales se observa en Scheffé (1959) que sobre ciertas condiciones

$$\frac{(\hat{L}_1 - \hat{L}_2)^t \left(\frac{V(\hat{L}_1 - \hat{L}_2)}{\sigma_e^2} \right) (\hat{L}_1 - \hat{L}_2)}{(t-1)CME} \sim F_{(t-1, gle)},$$

donde $\hat{L}_1$ y $\hat{L}_2$ son contrastes, los cuales estiman a L_1 y L_2 , respectivamente. En el espacio de las t -medias, $V(\hat{L}_1 - \hat{L}_2)$ es la matriz de varianzas y covarianzas de $\hat{L}_1 - \hat{L}_2$.

Consecuentemente, la región de confianza de tamaño $(1 - \alpha)$, es un elipsoide en que el diámetro máximo es tal que

$$P\left[|L_1 - L_2| \leq \sqrt{(t-1)F_{(t-1, gle, \alpha)} CME}\right] = 1 - \alpha.$$

Se observa que el método está basado en el diámetro máximo que representa la dirección de un contraste particular de varianza máxima.

3. Método de Bonferroni (Fisher)

Este método fue usado por primera vez por Fisher (1935) y originó la desigualdad de Bonferroni que tiene la siguiente base: “Para un conjunto de m contrastes, si cada uno es probado con un coeficiente de confianza de $1 - \alpha$, el coeficiente de confianza conjunto es por lo menos $1 - m\alpha$ ”.

El método de Bonferroni para comparaciones múltiples es adecuado para probar m contrastes y consiste en aplicar la prueba t -student a

cada uno de los contrastes usando un nivel de significación α/m , con eso queda garantizado que el coeficiente de confianza conjunta es $1 - \alpha$.

Si dos intervalos de confianza de una misma muestra para los contrastes L_1 y L_2 se obtienen, sean los eventos A_1 : el evento correspondiente al complemento del intervalo de confianza para L_1 y A_2 : análogo, pero para L_2 con $P(A_1) = P(A_2) = \alpha$.

Se sabe que $P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2)$ entonces $P[(A_1 \cup A_2)^c] = 1 - P(A_1 \cup A_2)$. Además, por la desigualdad de Boole: $P(A_1 \cup A_2) \leq P(A_1) + P(A_2)$, entonces $P(A_1^c \cap A_2^c) \geq 1 - P(A_1) - P(A_2) = 1 - 2\alpha$, el cual corresponde, en este caso, al evento región de confianza conjunta para L_1 y L_2 .

En el caso general de la cobertura de m eventos, se satisface que

$$P\left(\bigcap_{j=1}^m A_j^c\right) \geq 1 - m\alpha.$$

Observación 6.1. Cuanto mayor sea el número de contrastes m , menor es el nivel de significación para cada contraste particular, luego esta prueba se debe usar cuando m no es muy grande.

La hipótesis $H_0 : L = 0$ se rechaza a un nivel de significación α si

$$|\hat{L}| > t_{(gle, \varepsilon/2)} \sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}},$$

con $\varepsilon = \frac{2\alpha}{p(p-1)}$ cuando se comparan p medias de tratamientos.

4. Método basado en la amplitud máxima

Este método se basa en la distribución de las diferencias entre el mayor y el menor estadísticos de orden del conjunto de las medias muestrales.

Al considerar que $\bar{y}_{i.}$ es una variable aleatoria correspondiente a la media muestral, la cual se distribuye en forma normal, la distancia

$$Q = \frac{\max(\bar{y}_{i.}) - \min(\bar{y}_{i.})}{\sqrt{CME/r}} = \max_{1 \leq i \leq i' \leq t} \left\{ \frac{|\bar{y}_{i.} - \bar{y}_{i'.}|}{\sqrt{CME/r}} \right\}$$

se denomina la amplitud máxima estandarizada o estudentizada (rango estudentizado) con parámetros t y gle .

La distribución de esta estadística se encuentra tabulada para varios valores de α , es decir, existen tablas para valores $q_{(t,gle,\alpha)}$ (ver tabla A.12 del apéndice), tales que

$$P [Q \leq q_{(t,gle,\alpha)}] = 1 - \alpha.$$

Por lo tanto, se rechaza la hipótesis $H_0 : L = 0$ si $Q > q_{(t,gle,\alpha)}$.

Observación 6.2. La prueba t -student y de Bonferroni para contraste de dos medias pueden ser vistas como un caso particular de aplicación de la amplitud estudentizada.

5. Método de Tukey

Tukey (1953) propuso un método de comparación múltiple que también está basado en los intervalos o regiones de confianza. Este es usado para comparar la totalidad de los $\binom{t}{2}$ contrastes de medias de tipo

$$L = \mu_i - \mu_{i'}, \quad 1 \leq i \leq i' \leq t.$$

Si se considera que $n_1 = \dots = n_t = r$, se demuestra que $1 - \alpha$ es la probabilidad de que las $t(t-1)/2$ comparaciones de dos medias satisfagan simultáneamente la condición

$$(\bar{y}_i - \bar{y}_{i'}) \pm \sqrt{\frac{CME}{r}} q_{(t,gle,\alpha)},$$

siendo $q_{(t,gle,\alpha)}$ el valor correspondiente en la tabla A.12 del apéndice.

Luego con un nivel de significación α el estadístico de prueba para la hipótesis

$$H_0 : \mu_i = \mu_{i'} \text{ contra } H_a : \mu_i \neq \mu_{i'},$$

está dado por

$$\Delta = \sqrt{\frac{CME}{r}} q_{(t,gle,\alpha)}.$$

Si $|\hat{L}| = |\hat{\mu}_i - \hat{\mu}_{i'}| > \Delta$, se rechaza H_0 .

Observación 6.3. La prueba de Tukey exige en principio balanceamiento.

6. Método de Newman-Keuls (N-K)

Esta prueba fue diseñada por Newman (1939) y modificada por Keuls (1952), quien generó un nuevo interés en la prueba de Newman, por ello, el procedimiento se conoce como la prueba de Newman-Keuls.

Esta prueba es un procedimiento secuencial basado en la amplitud estandariza y es válido para la totalidad de contrastes de dos medias como en los métodos anteriores.

Se exige la condición de balanceamiento, es decir, $n_1 = \dots = n_t = r$, y el estadístico Q se estudia con parámetros p y gle , con p el número de medias ordenadas cubiertas por el contraste en estudio.

En la aplicación de la prueba se siguen los siguientes pasos:

- a) Ordenar las medias en un orden creciente o decreciente.
- b) Se compara la mayor media ($p' = p$) con la menor. Para esa comparación se determina $\sqrt{\frac{CME}{r}}q_{(p',gle,\alpha)}$ y la estimación del contraste; si el valor

$$NK_p = \sqrt{\frac{CME}{r}}q_{(p',gle,\alpha)} > |\hat{L}|,$$

las medias son cubiertas por una sublínea que permite determinar o afirmar que no hay diferencias significativas entre ellas. En el caso contrario, se hace el siguiente paso.

- c) Se reduce una unidad el valor de p' calculándose de nuevo el valor de CME , es decir, $\sqrt{\frac{CME}{r}}q_{(p',gle,\alpha)}$; y para todos los pares de medias que no estén cubiertos por una misma línea y que cubren p' medias, se repite el proceso de comparación.
- d) Se repite c) hasta que $p' = 1$.

Observación 6.4. Esta prueba tiene como inconveniente que, como las medias ordenadas no son independientes, el valor de $q_{(p',gle,\alpha)}$ no es exacto.

Nota:

- i) La prueba de N-K es un procedimiento secuencial válido para la totalidad de los contrastes de dos medias.
- ii) N-K exige en principio balanceamiento.
- iii) N-K es una prueba aproximada.

7. Método de Duncan

Constituye también un procedimiento secuencial válido para la comparación del contraste de dos medias. La prueba está basada en la amplitud estudentizada $q_{(p',gle,\alpha)}$. En este caso, tanto p' como α varían

durante la aplicación de la prueba; p' es el número de medias ordenadas cubiertas por el contraste en estudio y α es el nivel de significación considerado en cada paso de aplicación de la prueba.

Para un contraste sobre p medias ordenadas el valor de α es igual a $1 - (1 - \alpha)^{p-1}$.

Los pasos para la aplicación de la prueba estadística son los mismos que los de N-K, solo que los valores del contraste son comparados con

$$D = \sqrt{\frac{CME}{r}} q_{(p', gle, \gamma_p)},$$

donde $\gamma_p = 1 - (1 - \alpha)^{p-1}$ es el nivel de significación, tomado como si se incluyeran $p - 1$ contrastes ortogonales en cada paso; y cada valor de D es calculado como si las medias fueran independientes, pero como están ordenadas no van a ser independientes.

La regla de decisión es rechazar H_0 si $|\bar{y}_i - \bar{y}_{i'}| \geq \sqrt{\frac{CME}{r}} q_{(p', gle, \gamma_p)}$.

Teniendo como casos particulares:

Prueba t	$p' = 2$	$\alpha' = \alpha$
Prueba de Bonferroni	$p' = 2$	$\alpha' = \alpha/m$
Prueba de Tukey	$p' = p$	$\alpha' = \alpha$
Prueba N-K	$p' = p, p - 1, \dots, 2$	$\alpha' = \alpha$
Prueba de Duncan	$p' = p, p - 1, \dots, 2$	$\alpha' = 1 - (1 - \alpha)^{p'}$

8. Método de Dunnett

Dunnett (1955) desarrolla un procedimiento para comparar un tratamiento control (testigo) con otros tratamientos. Sean μ_T y μ_i ($i = 1, 2, \dots, t$) las medias poblacionales del control y de los demás $p = t - 1$ tratamientos, y n_T y n_i las correspondientes replicaciones.

Para la totalidad de los contrastes $L = \mu_i - \mu_T$, se tiene que

$$P \left[|L - \hat{L}| < d_{(p, gle, \alpha)} \sqrt{\left(\frac{1}{n_i} + \frac{1}{n_T} \right) CME} \right] = 1 - \alpha.$$

Con un nivel α de significación se rechaza H_0 si

$$|\bar{y}_i - \bar{y}_T| \geq d_{(p, gle, \alpha)} \sqrt{\left(\frac{1}{n_i} + \frac{1}{n_T} \right) CME}.$$

Observación 6.5. Es conveniente usar más observaciones en el tratamiento control que en los otros tratamientos.

En la tabla A.13 del anexo se presentan los valores críticos para la prueba de Dunnett asociados con algunos valores de α ($d_{(p,gle,\alpha)}$).

A continuación se ilustran numéricamente algunos de los métodos estudiados.

Ejemplo 6.1. Para los datos del ejemplo 5.1, al plantear la hipótesis de igualdad de dietas $H_0 : \mu_{D_1} = \mu_{D_2} = \mu_{D_3} = \mu_{D_4}$, se concluye que esta hipótesis se rechaza. De esta forma, se encuentran diferencias entre dietas. Ahora, se tiene interés en conocer cuáles son las dietas más efectivas, es decir, se desea probar la hipótesis: $H_0 : \mu_{D_i} = \mu_{D_{i'}}, i \neq i', i, i' = 1, 2, 3, 4$, con algunas de las estadísticas planteadas con anterioridad.

i. Prueba t de Student

El valor del estadístico

$$LSD = t_{(16,0.025)} \sqrt{10.36 \left(\frac{1}{5} + \frac{1}{5} \right)} = (2.12)(2.04) = 4.32.$$

Con este resultado se sigue que una pareja de medias difiere significativamente si el valor absoluto de la diferencia de los promedios en los tratamientos correspondientes es mayor a 4.32. Los cuatro promedios de tratamiento son

$$\bar{y}_{1.} = -2.82, \bar{y}_{2.} = -7.92, \bar{y}_{3.} = -0.02 \text{ y } \bar{y}_{4.} = -4.78,$$

y las diferencias de los promedios en valor absoluto son:

$$|\bar{y}_{1.} - \bar{y}_{2.}| = |-2.82 + 7.92| = 5.10$$

$$|\bar{y}_{1.} - \bar{y}_{3.}| = |-2.82 + 0.02| = 2.80$$

$$|\bar{y}_{1.} - \bar{y}_{4.}| = |-2.82 + 4.78| = 1.96$$

$$|\bar{y}_{2.} - \bar{y}_{3.}| = |-7.92 + 0.02| = 7.90$$

$$|\bar{y}_{2.} - \bar{y}_{4.}| = |-7.92 + 4.78| = 3.14$$

$$|\bar{y}_{3.} - \bar{y}_{4.}| = |-0.02 + 4.78| = 4.76.$$

Las diferencias entre medias comparadas con el estadístico de prueba difieren. Las diferencias encontradas con los diferentes estadísticos de prueba se resumen en la tabla 6.1.

ii. Método de Bonferroni

Con esta prueba se obtiene

$$\varepsilon = \frac{2\alpha}{p(p-1)} = \frac{0.10}{12} = 0.008.$$

Tabla 6.1: Significación de las diferencias en valor absoluto entre las medias de las dietas a través de cuatro métodos de comparación no-planeada

Diferencia entre dietas	<i>t</i> -Student	Bonferroni	Tukey
1-2	Signif	No sig	No sig
1-3	No sig	No sig	No sig
1-4	No sig	No sig	No sig
2-3	Signif	Signif	Signif
2-4	No sig	No sig	No sig
3-4	Signif	No sig	No sig

Por consiguiente,

$$t_{(16, 0.008/2)} \sqrt{10.36 \left(\frac{1}{5} + \frac{1}{5} \right)} = (3.01)(2.04) = 6.14.$$

Luego, las únicas dietas que difieren significativamente según esta prueba son las 2 y 3, como se muestra en la tabla 6.1.

iii. Método de Tukey

En este caso el valor del estadístico es

$$\Delta = \sqrt{\frac{10.36}{5}} q_{(4, 16, 0.05)} = (1.44)(4.05) = 5.83.$$

Con este resultado las únicas dietas que difieren significativamente son las 2 y 3, obteniéndose un resultado similar al encontrado con el método de Bonferroni.

iv. Método de Newman-Keuls (N-K)

Para desarrollar esta prueba se organizan, en primer lugar, los promedios de las dietas en orden ascendente

$$\bar{y}_{2.} = -7.92$$

$$\bar{y}_{4.} = -4.78$$

$$\bar{y}_{1.} = -2.82$$

$$\bar{y}_{3.} = -0.02.$$

El error estándar de cada promedio es $\sqrt{\frac{10.36}{5}} = 1.44$. Usando la tabla A.12 del apéndice, con 16 grados de libertad y $\alpha = 0.05$, los intervalos significativos son $q_{(2, 16, 0.05)} = 3.00$, $q_{(3, 16, 0.05)} = 3.65$ y $q_{(4, 16, 0.05)} = 4.05$. Así, los NK_p significativos son

$$NK_2 = (1.44)(3.00) = 4.32$$

$$NK_3 = (1.44)(3.65) = 5.25$$

$$NK_4 = (1.44)(4.05) = 5.83.$$

Al hacer las comparaciones, se tiene

$$\bar{y}_{3.} - \bar{y}_{2.} = -0.02 + 7.92 = 7.90 > 5.83(NK_4)$$

$$\bar{y}_{3.} - \bar{y}_{4.} = -0.02 + 4.78 = 4.76 < 5.25(NK_3)$$

$$\bar{y}_{3.} - \bar{y}_{1.} = -0.02 + 2.82 = 2.80 < 4.32(NK_2)$$

$$\bar{y}_{1.} - \bar{y}_{2.} = -2.82 + 7.92 = 5.10 < 5.25(NK_3)$$

$$\bar{y}_{1.} - \bar{y}_{4.} = -2.82 + 4.78 = 1.96 < 4.32(NK_2)$$

$$\bar{y}_{4.} - \bar{y}_{2.} = -4.78 + 7.92 = 3.14 < 4.32(NK_2).$$

A partir de este análisis se observa, al igual que los dos casos anteriores, que la única diferencia significativa entre los promedios de las dietas se encuentra entre las dietas 2 y 3.

6.1.2.1. Algunos comentarios sobre comparaciones múltiples

Las pruebas de Tukey y de Duncan tienen bases muy semejantes, sin embargo, la prueba de Duncan genera diferencias significativas con más facilidad, ya que al formular un nivel de significación del 5 % la probabilidad de que un contraste incluya dos medias exige una probabilidad del 95 % de que no se encuentre una diferencia realmente nula. Para el caso de tres medias la probabilidad será de $(0.95)^2$, en el caso de t medias la probabilidad será de $(0.95)^{t-1}$; en tanto que la prueba de Tukey es más exigente, mantiene siempre una probabilidad de 0.95 de no encontrar una diferencia realmente nula entre todas las medias de los tratamientos. La prueba de Duncan aplicada ampliamente no es muy rigurosa, por lo cual debe ser usada con mucha cautela. Así, la prueba de Duncan es un intermedio entre el excesivo rigor de la prueba de Tukey y la falta de rigor de la prueba t -student.

La prueba de Scheffé es aún más rigurosa, no es recomendable para la comparación de dos medias, pero puede usarse en contrastes más amplios (de más de dos medias), esta es más poderosa que el método de Bonferroni si el número de comparaciones es relativamente más grande que el número de medias.

6.2. Verificación de supuestos

En esta sección se parte de la definición del residual $\hat{\epsilon}_i = y_i - \hat{y}_i$, sobre el cual se hacen algunos supuestos que es necesario verificar con el fin de realizar inferencias válidas sobre el modelo (ajuste, adecuación, validez de la predicción, etc). La validación lleva en consideración la realización de un análisis de los residuales para verificar cualquier anomalía sobre el ajuste del modelo lineal.

Cuando se propone un modelo para el ajuste de los datos se establecen básicamente los siguientes supuestos sobre el error: independencia, normalidad, media cero y varianza constante.

Es importante notar que los errores (ϵ_i) son no observables, no se conocen, pero se pueden estimar mediante los residuales ($\hat{\epsilon}_i$); así, todas las pruebas de los supuestos se realizan sobre estos últimos. Al ajustar el modelo se espera que los residuales satisfagan los anteriores supuestos sobre el error. Después de examinar los residuales solo se podrá concluir que los supuestos “se cumplen” o “no se cumplen”.

Esto último no significa que los supuestos se cumplan, sino que sobre la base de los datos se ha visto que no hay razón para decir que los supuestos no se satisfacen.

Toda la inferencia que se puede realizar (estimación por intervalo de las combinaciones lineales o no lineales de los parámetros, pruebas de hipótesis, entre otras) sobre el modelo tiene como base los supuestos sobre la variable respuesta. Si alguno de estos no se cumple, los procesos de inferencia conllevan a decisiones equivocadas.

El objetivo de esta sección es mostrar los posibles problemas que se presentan cuando alguno de los supuestos no se cumple, así como mostrar diferentes formas de corregir las desviaciones de los supuestos en el caso de que no se cumplan.

El supuesto de media cero de los errores verificado a través de los residuales es de fácil cumplimiento, puesto que el promedio de los errores por construcción es cero.

6.2.1. Causas de desvíos de supuestos

No se debe aplicar una técnica estadística sin antes verificar que los supuestos del modelo son razonablemente satisfechos. Se aconseja que un análisis estadístico se inicie con un estudio exploratorio de datos, con eso se gana sensibilidad e información adicional sobre la variable estudiada.

El análisis de residuos es una técnica bastante eficiente para detectar desvíos de los supuestos. Abarca análisis gráficos, numéricos y mixtos; debe ser un procedimiento de rutina en el análisis de los datos. El análisis de residuos también puede ser utilizado para detectar *outliers*.

Los supuestos básicos que se deben verificar en el ajuste de los modelos son los siguientes:

- i. *La no correlación de los errores*: este supuesto se incumple cuando las observaciones son tomadas secuencialmente en el tiempo, el espacio y en datos *cluster*, entre otros. Cuando los datos están correlacionados se debe trabajar con métodos estadísticos apropiados.
- ii. *La homocedasticidad de los errores*: este supuesto se puede incumplir por razones como: daños en alguna parte del experimento, contratiempos, uso del material experimental menos homogéneo en algunas réplicas, por no tener cuidado en el control durante la ejecución del experimento o en el control de las unidades experimentales, entre otras.

La naturaleza de los tratamientos puede producir algunas respuestas más variables que otras, causando heterogeneidad en la varianza de los errores, caso frecuente en ensayos con fertilizantes o en experimentación biológica cuando se desea comparar efectos de tratamientos.

La heterocedasticidad puede ocurrir también en los casos donde la media y la varianza están relacionadas. Un caso típico es el estudio de conteos que siguen una distribución Poisson o en datos con respuesta binaria. También la heterocedasticidad puede ser causada por la presencia de observaciones atípicas u *outliers*, las cuales se clasifican en “no genuinas” o “genuinas”. Las primeras son datos leídos pero con transcripción errónea, en tanto que las genuinas pueden ser causadas por cambios no controlados en la conducción del experimento.

- iii. *La normalidad*. Casi nunca ocurre con la información real proveniente de los datos, la distribución de la variable puede ser asimétrica y aun con distribución simétrica puede no seguir una distribución normal.
- iv. *No aditividad en el modelo*. La construcción de gráficos de perfiles puede indicar la existencia o no de interacción. Para verificar si dicha interacción es causada por la presencia de un *outlier*, tal observación se debe retirar y se debe rediseñar el gráfico. Si se mantiene la estructura de este gráfico, existen indicios de que la interacción es inherente al fenómeno de estudio y no es causada por la presencia del *outlier*.

A continuación se presentan los métodos y pruebas para detectar problemas de no homocedasticidad, no normalidad y no aditividad en el modelo.

6.2.2. Análisis gráfico y medidas descriptivas de los residuales

Como es sabido, las formas gráficas y las medidas descriptivas son los métodos usados tradicionalmente para detectar problemas en la validez de los supuestos del modelo lineal planteado; por su importancia, en esta sección se presentan algunos de estos métodos.

1. **Histogramas y gráfico probabilístico normal.** Estos gráficos son útiles para analizar la normalidad de los residuos e identificar valores atípicos. La potencia de las pruebas de normalidad sobre los residuos suele ser baja, porque, aunque el vector de variables aleatorias no sea normal, es posible que los residuos lo sean. La razón es que $\hat{\epsilon}_i$ es una combinación lineal de todas las variables aleatorias y, según el teorema central del límite, su distribución tenderá a ser aproximadamente normal. Los histogramas pueden ayudar a detectar la falta de normalidad.

En la aplicación del método se deben tener en cuenta los siguientes pasos:

- a) Ordene los valores de la variable aleatoria W de menor a mayor ($w_{(1)} < \dots < w_{(n)}$).
- b) Calcule la probabilidad acumulada observada: $p_i = 100(i - 0.5)/n$. El valor de 0.5 se emplea para no obtener $p = 1$, el cual tiene un valor de infinito para W . El arreglo que se tiene para esta información es el siguiente:

W	Percentil (p)
$w_{(1)}$	p_1
$\vdots$	$\vdots$
$w_{(n)}$	p_n

- c) Grafique los valores de W contra P .

Observaciones que no proceden de una distribución normal presentan una forma curva, mientras observaciones que se ajusten a la normalidad siguen una ecuación lineal. Este método se recomienda con tamaños de muestra donde $n > 100$ observaciones (Sokal y Rohlf 1969).

Si hay un ajuste cercano a una línea recta, hay evidencia para indicar que los datos provienen de una distribución normal. Sin embargo, se debe tener en cuenta que, *en algunos casos, aunque los puntos se ajusten a una línea recta, puede que los datos no provengan de una distribución normal*. Por ello, se recomienda utilizar algunos otros “métodos objetivos”.

Otra alternativa para realizar el gráfico de probabilidad normal se basa en la estandarización de las observaciones mediante la transformación a la variable z_i , $i = 1, \dots, n$,

$$z_i = \frac{w_i - \mu}{\sigma}, \quad i = 1, \dots, n.$$

La idea es calcular la probabilidad de cada una de las observaciones y estimar el valor de z_i aplicando la función inversa. Si la distribución adyacente es normal, el gráfico de los valores de z_i versus w_i tienen una forma lineal.

2. **Gráfico de residuos frente a valores estimados.** Con estos gráficos se pueden identificar la falta de linealidad, la heterocedasticidad y la presencia de valores atípicos. El gráfico puede hacerse con cualquiera de los tipos de residuos, aunque, preferiblemente, se utilizan los residuos sin transformar $\hat{\epsilon}_i$ o los estandarizados r_{i0} , donde

$$r_{i0} = \frac{\hat{\epsilon}_i}{\sqrt{CME[1 - x_i(X^t X)^{-1}x_i^t]}}$$

con x_i la i -ésima fila de la matriz X .

3. **Gráfico de residuos frente a factores o variables explicativas.** Puede ayudar a detectar si la falta de linealidad o heterocedasticidad es debida a algún factor específico. En este caso, es conveniente realizar los gráficos parciales de los residuos de cada factor incluido en el modelo para detectar en dónde se presenta la heterocedasticidad.
4. **Gráficos parciales de residuos.** Con estos gráficos se estudia la relación entre una variable respuesta y alguna explicativa eliminando el efecto de las restantes variables explicativas. Para la construcción del gráfico se debe:
 - a) Ajustar un modelo lineal entre la respuesta y los factores o variables cuyos efectos se trata de eliminar.
 - b) Obtener los residuos del modelo, que representan la parte de la respuesta no explicada por las otras variables.
 - c) Graficar el vector de variables aleatorias.

5. **Gráficos de residuales frente a factores o variables omitidas.** La posible influencia de un nuevo factor o variable no incluida en el análisis se puede detectar graficando la variable omitida con los residuos; en particular, siempre que las observaciones se hayan obtenido en orden temporal, es conveniente representar los residuos en función del tiempo. Esto permite ver posibles autocorrelaciones entre las observaciones.
6. **Se deben inspeccionar las varianzas muestrales de los grupos analizados.** Hay indicios de falta de homocedasticidad cuando son muy pronunciadas.
7. **El cálculo de la amplitud de la varianza.** Este puede indicar heterocedasticidad si las amplitudes para los diferentes grupos estudiados fueron distintas.
8. **El cálculo de los coeficientes de variación.** Este puede indicar heterocedasticidad. Si los grupos presentan coeficientes de variación semejantes, esto indica que la varianza crece con la media. Si las medias fueran semejantes, los coeficientes de variación pueden indicar que las varianzas no son constantes.

Ejemplo 6.2. Con los datos del ejemplo 5.1, se realiza a continuación el análisis gráfico de los residuales obtenidos del DCA propuesto.




Figura 6.1: Análisis gráfico de los residuales.

Según los gráficos de la figura 6.1, no parecen existir problemas en el modelo planteado, es decir, la homocedasticidad (los valores ajustados versus los residuales

no presentan un patrón sistemático), normalidad (en el histograma los residuales parecen seguir una distribución normal y en el gráfico de probabilidad normal, los mismos parecen ajustarse a una línea recta) y la no autocorrelación (no se observa algún patrón en el gráfico de residuales ordenados) en los residuales es satisfecha. Sin embargo, no basta con la simple visualización de los gráficos, sino que se deben realizar las pruebas estadísticas pertinentes que confirmen las anteriores afirmaciones.

6.2.3. Prueba para detectar anomalías

- Para detectar heterocedasticidad, se puede usar el estadístico Cochran, de Hartley o el de Bartlett; los dos primeros son apropiados para datos balanceados. Cuando las poblaciones no son normales, la estadística de Box y Anderson (1955) puede ser empleada.
- Para detectar la falta de normalidad, se tiene la χ^2 de Pearson, la cual puede estudiarse en Snedecor y Cochran (1967); las pruebas de Kolmogorov-Smirnov, Shapiro-Wilk y Lilliefors pueden estudiarse en Conover (1980).

También se puede estudiar la estadística de asimetría

$$r_1 = \frac{E(Y - \mu)^3}{\sigma^3},$$

donde

$$r_1 = \begin{cases} > 0 & \text{distribución asimétrica a la derecha} \\ = 0 & \text{distribución simétrica} \\ < 0 & \text{distribución asimétrica a la izquierda} \end{cases}$$

y la estadística de curtosis

$$r_2 = \frac{E(Y - \mu)^4}{\sigma^4},$$

donde

$$r_2 = \begin{cases} > 3 & \text{leptocúrtica} \\ = 3 & \text{normal} \\ < 3 & \text{platicúrtica} \end{cases}$$

- Para detectar correlación de los errores se usan los estadísticos de Spearman y del signo (Conover 1980) o la prueba de Durbin-Watson (Graybill 1976).

- d. No aditividad: si hay suficientes grados de libertad, el estadístico F de análisis de varianza puede ser usado. Sin embargo, la prueba propuesta por Tukey para experimentos cruzados con dos factores fijos es el más usado. Para diseños en cuadro latino se recomienda el estadístico de Wilk y Kempthorne (1957).

En las siguientes secciones se presentan algunas de las anteriores pruebas, las cuales, se espera, sean de gran ayuda en el desarrollo de los siguientes capítulos.

6.2.4. Pruebas para detectar heterocedasticidad

Lo contrario a homocedasticidad es la heterocedasticidad, que consiste en que la varianza cambia a través de las observaciones. Cuando la varianza cambia de individuo a individuo o de tratamiento a tratamiento, se dice que los errores son heterocedásticos.

Las consecuencias que produce la heterocedasticidad son:

- a. Los estimadores de mínimos cuadrados o de máxima verosimilitud siguen siendo insesgados pero no son de mínima varianza.
- b. El estimador de la varianza de los errores es sesgado y, por ende, las varianzas de combinaciones de los estimadores de parámetros son erradas, conllevando esto a que las pruebas estadísticas no sean válidas.

A continuación se presentan algunos estadísticos de prueba para la detección de anomalías y la solución a este problema.

6.2.4.1. Prueba de Bartlett de homogeneidad de varianzas

La prueba de Bartlett (1937) es quizá la más ampliamente usada para probar homogeneidad de varianza. Para introducir el test, se considerarán k poblaciones, a través de estas el objetivo de la prueba se centra en determinar si todas tienen la misma varianza. Para la realización adecuada de esta prueba, se exige que las poblaciones sean independientes y se distribuyan normalmente.

La prueba es frecuentemente llamada M de Bartlett o también Neyman-Pearson-Bartlett. Su aplicación básica, como ya se mencionó, es para la comparación de varianzas (homogeneidad de varianzas) entre grupos, pero también puede ser usada para chequear homogeneidad en interacciones de mayor grado en experimentos factoriales.

En la conducción de la prueba se suponen k poblaciones normales con media μ_i y varianza σ_i^2 ($i = 1, \dots, k$). Si de cada una de las poblaciones se toman muestras aleatorias de tamaño n_i independientes y se observa la característica de interés $\{w_{ij}\}$, con $j = 1, \dots, n_i$, se plantea la hipótesis

$$H_0 : \sigma_1^2 = \dots = \sigma_k^2$$

versus

$$H_a : \sigma_i^2 \neq \sigma_{i'}^2 \text{ para algún } i \neq i', i, i' = 1, 2, \dots, k.$$

Se propone el estadístico de prueba:

$$L = \frac{\prod_{i=1}^k (s_i^2)^{v_i/v}}{\sum_{i=1}^k (v_i/v) s_i^2},$$

donde $v_i = n_i - 1$, $v = \sum_{i=1}^k v_i$ y $s_i^2 = \sum_{j=1}^{n_i} \frac{(w_{ij} - \bar{w}_{i.})^2}{n_i - 1}$, con $\bar{w}_{i.} = \frac{1}{n_i} \sum_{j=1}^{n_i} w_{ij}$, $i = 1, 2, \dots, k$.

La prueba de Bartlett de homogeneidad de varianzas tiene como región crítica $0 < L < A$, donde A se determina por el tamaño de la prueba.

En particular, si se tiene un valor crítico de tamaño α , A se determina por la ecuación $P_{H_0}(0 < L < A) = \alpha$.

Observación 6.6.

- i. s_i^2 estima insesgadamente a σ_i^2 , $i = 1, 2, \dots, k$.
- ii. El numerador de L es una media geométrica ponderada (MGP) de s_i^2 , donde el factor de ponderación son los grados de libertad.
- iii. El denominador de L es la correspondiente media aritmética ponderada (MAP) de s_i^2 , donde la ponderación son los grados de libertad.
- iv. Es bien conocido que la relación $(\text{MGP})/(\text{MAP}) \leq 1$. La igualdad se satisface siempre que $s_1 = s_2 = \dots = s_k$.
- v. Valores altos de L sugieren valores semejantes de σ_i^2 y valores bajos sugieren gran dispersión entre los σ_i^2 .
- vi. Los valores críticos de A se obtienen en tablas; existen dos tipos de tablas: una basada en la distribución nula aproximada de L y la otra basada en la distribución exacta (Pearson y Hartley 1996).

Hartley introduce una modificación al estadístico de Bartlett, obteniendo la siguiente expresión:

$$M_1 = -v \ln L = v \ln \left(\sum_{i=1}^k \frac{v_i}{v} s_i^2 \right) - \sum_{i=1}^k v_i \ln s_i^2,$$

la cual bajo H_0 cierta tiene una distribución asintótica $\chi_{(k-1)}^2$.

Una aproximación a la $\chi_{(k-1)}^2$, cuando v_i es finita, sugerida por Bartlett consiste en usar el estadístico

$$T = \frac{M_1}{C} \sim \chi_{(k-1)}^2,$$

con

$$C = 1 + \frac{1}{3(k-1)} \left(\sum_{i=1}^k \frac{1}{v_i} - \frac{1}{v} \right).$$

En este caso, se rechaza H_0 si $T > \chi_{(k-1)}^2$.

Ejemplo 6.3. *Los residuales obtenidos al realizar el experimento del ejemplo 5.1 se presentan en la tabla 6.2.*

Tabla 6.2: Residuales de la pérdida o ganancia de peso en kilogramos de 20 personas que asistieron a un gimnasio al aplicarles una dieta

Réplica	D_1	D_2	D_3	D_4
1	-6.48	-2.18	1.52	1.58
2	5.32	2.92	-1.98	-0.82
3	-2.58	0.72	-0.48	-3.62
4	-0.78	-1.28	3.42	-0.52
5	4.52	-0.18	-2.48	3.38
v_i	4	4	4	4
s_i^2	24.50	3.87	6.08	6.99

Para juzgar la hipótesis

$$H_0 : \sigma_1^2 = \sigma_2^2 = \sigma_3^2 = \sigma_4^2$$

contra

$$H_a : \sigma_i^2 \neq \sigma_{i'}^2, \text{ para algún } i \neq i', i, i' = 1, 2, 3, 4,$$

haciendo uso del estadístico propuesto por Bartlett, se encuentra que

$$M_1 = 37.40 - 33.20 = 4.20 \quad \text{y} \quad C = 1 + \frac{1 - 0.06}{9} = 1.10.$$

Por consiguiente,

$$T = \frac{4.20}{1.10} = 3.82.$$

Como $T = 3.82 < \chi^2_{(3,0.05)} = 7.81$ no hay evidencia estadística para rechazar H_0 , con lo cual se concluye que hay homogeneidad en los residuales. Nótese que para la realización de esta prueba es necesario el cumplimiento de los supuestos de independencia y de normalidad, este último será verificado en la siguiente sección.

Observación 6.7. Existe otra prueba clásica de igualdad de varianzas, conocida como la estadística de Cochran, la característica de esta junto con la de Bartlett y Hartley es que se basa en datos con distribución normal y son extremadamente sensibles cuando esto no ocurre. Si la normalidad no se presenta, existen otras pruebas bastante robustas, pero involucran cálculos bastante engorrosos.

Hartley (1950) compara el estadístico

$$M_2 = \frac{s_{\max}^2}{s_{\min}^2} = \frac{\max\{s_1^2, \dots, s_k^2\}}{\min\{s_1^2, \dots, s_k^2\}}.$$

Con el percentil superior 100α % de la distribución F , la hipótesis nula de igualdad de varianzas se rechaza si $M_2 > F_{(gl(s_{\max}^2), gl(s_{\min}^2), \alpha)}$.

6.2.4.2. Prueba de razón de verosimilitud (RV)

La prueba RV es aplicable cuando el número de observaciones de la muestra es grande. El primer paso para la aplicación de esta prueba consiste en dividir los residuos obtenidos por el método de mínimos cuadrados ordinarios (MCO) en k grupos, cada uno con n_i observaciones tal que $n = \sum_i n_i$, donde n es el número de observaciones en la muestra. Luego, se estima la varianza de los residuos para cada subgrupo (s_i^2) y la varianza de los residuos para toda la muestra (s^2). A partir de esta información se define una función λ de la forma

$$\lambda = \prod_{i=1}^k \frac{s_i^{n_i}}{s^n},$$

donde s es la desviación estándar muestral de los datos. Se demuestra que $-2 \ln \lambda$ se distribuye como una $\chi^2_{(k-1)}$.

El paso final consiste en comparar la siguiente relación $-2 \ln \lambda > \chi^2_{(k-1, \alpha)}$. Si no se cumple, se rechaza la hipótesis nula de homocedasticidad entre grupos. Si existe solo una variable explicativa, el ordenamiento de los residuos se puede hacer sobre la base de las magnitudes absolutas de estos.

Sin embargo, si existiesen dos o más variables explicativas se puede utilizar el valor estimado ($\hat{y}$) para hacer el ordenamiento de los residuales.

6.2.4.3. Prueba de Spearman

Esta prueba supone que la varianza del término de error depende de los valores de predicción. Si existe esta dependencia, el tamaño de los residuos debería estar relacionado con el tamaño de la variable predicha. Se debe tener en cuenta en estos casos que las variaciones en el término de error tienden a ser pequeñas cuando las predicciones registran valores pequeños y grandes cuando las variables involucradas muestran valores elevados.

Para llevar a cabo esta prueba, es necesario ordenar en sentido creciente tanto los residuos obtenidos a través de la estimación MCO (en valor absoluto) como los valores de las predicciones. Una vez obtenido este ordenamiento, se calcula el coeficiente de correlación de rangos r_{Sp} con la expresión

$$r_{Sp} = 1 - \frac{6 \sum_{i=1}^n D_i^2}{n(n^2 - 1)},$$

donde D_i es la diferencia entre el puesto que ocupan en la ordenación el valor de la i -ésima predicción y el i -ésimo valor absoluto del residuo.

Si n está entre 4 y 30, se compara el valor calculado de r_{Sp} con el valor crítico, r_{Sp}^* , de la tabla A.14 del apéndice. Se rechaza H_0 al nivel de significación α si r_{Sp} es mayor que r_{Sp}^* .

Si el tamaño muestral es grande, entonces la expresión

$$t = \frac{r_{Sp} \sqrt{n-2}}{\sqrt{1-r_{Sp}^2}}$$

se distribuye aproximadamente como una t -student con $(n-2)$ grados de libertad. Esta expresión podría calcularse para cada una de las variables explicativas del modelo con el fin de determinar si alguna de ellas determina el comportamiento de la varianza del término de error. Específicamente, si el valor calculado del estadístico t es menor al valor tabulado, no se tiene evidencia para rechazar la hipótesis nula de homocedasticidad respecto a los residuos analizados.

6.2.4.4. Prueba de Levene

Esta prueba fue propuesta por Levene (1960). La prueba es robusta respecto al supuesto de normalidad. Para su implementación se debe reemplazar cada

valor observado w_{ij} por $z_{ij} = |w_{ij} - \bar{w}_{i\cdot}|$ y luego realizar el análisis de varianza a una vía. Se rechaza H_0 si la prueba es significativa.

Ejemplo 6.4. *A partir de los residuales obtenidos al realizar el experimento del ejemplo 5.1 y teniendo en cuenta los resultados del ejemplo 6.3, se ilustraran a continuación las pruebas de homocedasticidad presentadas en las secciones 6.2.4.1, 6.2.4.2 y 6.2.4.3.*

a. Prueba de Hartley

$$M_2 = \frac{24.50}{3.87} = 6.33$$

al comparar con una $F_{(4,4,0.05)} = 6.39$, la hipótesis de homogeneidad de varianzas entre residuales no se rechaza.

b. Prueba de razón de verosimilitud (RV)

$$\lambda = \prod_{i=1}^4 \frac{s_i^{n_i}}{s^n} = \frac{(4.95)^5 (1.97)^5 (2.47)^5 (2.64)^5}{(2.95)^{80}}.$$

De este modo, como $-2 \ln \lambda = 131.56 > \chi^2_{(3,0.05)} = 7.82$, no se rechaza la hipótesis de homocedasticidad, encontrando un resultado similar al hallado en las dos pruebas anteriores.

c. Prueba de Levene

En este caso, en la tabla 6.3 se muestra el análisis de varianza para las $z_{ij} = |w_{ij} - \bar{w}_{i\cdot}|$ a una vía de clasificación. A partir de los resultados obtenidos en esta tabla, al igual que en los otros casos, no se rechaza la hipótesis de homocedasticidad entre los residuales (valor $p = 0.098$).

Tabla 6.3: Análisis de varianza para los residuos de Levene

C de V	gl	SC	CM	F	Valor p
Tratam.	3	17.94	5.98	2.49	0.098
Error	16	38.47	2.40		
Total	19	56.41			

Por otro lado, utilizando $z_{ij}^* = |w_{ij} - \tilde{w}_{i\cdot}|$, donde $\tilde{w}_{i\cdot}$ es la mediana, se obtienen los resultados de la tabla 6.4. A partir de esta tabla, nuevamente no se rechaza la hipótesis de homocedasticidad entre los residuales (valor $p = 0.225$).

Tabla 6.4: Análisis con mediana para los residuos de Levene

C de V	gl	SC	CM	F	Valor p
Tratam.	3	16.52	5.51	1.61	0.225
Error	16	54.57	3.41		
Total	19	71.09			

d. *Prueba de Spearman*

Para la realización de esta prueba, es necesario ordenar en sentido creciente tanto los residuos como los valores de las predicciones, en la tabla 6.5 se presentan estos valores.

Tabla 6.5: Diferencia entre los rangos de los valores predichos y los residuales para la prueba de Spearman

Valor predicho	Residual	Rango $\hat{y}$	Rango $ \hat{\epsilon} $	Diferencia
-2.82	-6.48	13	20	-7
-2.82	5.32	13	19	-6
-2.82	-2.58	13	13	0
-2.82	-0.78	13	5	8
-2.82	4.52	13	18	-5
-7.92	-2.18	3	11	-8
-7.92	2.92	3	14	-11
-7.92	0.72	3	4	-1
-7.92	-1.28	3	7	-4
-7.92	-0.18	3	1	2
-0.02	1.52	18	8	10
-0.02	-1.98	18	10	8
-0.02	-0.48	18	2	16
-0.02	3.42	18	16	2
-0.02	-2.48	18	12	6
-4.78	1.58	8	9	-1
-4.78	-0.82	8	6	2
-4.78	-3.62	8	17	-9
-4.78	-0.52	8	3	5
-4.78	3.38	8	15	-7

Con esta información, el coeficiente de correlación de rangos de Spearman es

$$r_{Sp} = 1 - \frac{6(1000)}{20(400 - 1)} = 0.25.$$

Al comparar este valor con $r_{Sp}^* = 0.3789$ a un nivel de significación del 5%, se encuentra que no hay evidencia estadística para rechazar la hipótesis de homocedasticidad respecto a los residuos.

Recomendaciones

Conover, Johnson y Johnson (1981) realizaron un estudio de pruebas de homogeneidad de varianza como las citadas anteriormente. Con base en estos resultados, hacen las siguientes recomendaciones:

1. Si hay confianza de que la variable (en este caso error) está cercana a una distribución normal, entonces use la prueba de Bartlett o Hartley. Si los tamaños de muestra son muy desiguales, use la prueba de Bartlett; en otro caso, la prueba de Hartley.
2. Si los datos no son normales y se tiene un tamaño de muestra grande, use la prueba de Levene. Esta prueba es muy robusta a la normalidad, pero *no es muy potente en muestras de tamaño pequeño*.
3. En todas las demás situaciones, usar Levene, la cual es tan buena como Bartlett y Hartley cuando los datos provienen de una distribución normal y es superior a ellas para distribuciones de datos no normales. Si los datos tienden a ser muy sesgados, la prueba de Levene puede ser mejorada reemplazando $\bar{w}_i$ por $\tilde{w}_i$, donde $\tilde{w}_i$ es la mediana del i -ésimo grupo. En este caso, se debe usar $z_{ij} = |w_{ij} - \tilde{w}_i|$ y el análisis de varianza se hace sobre los z_{ij} .

Como se ha visto a lo largo de esta sección, es importante el cumplimiento del supuesto de normalidad para la realización de las pruebas de homocedasticidad y para la validez del modelo, por su importancia, en la siguiente sección se presenta una discusión del tema.

6.2.5. Pruebas de normalidad

La distribución normal es fundamental para la mayoría de los análisis estadísticos que se plantean en este texto. Existen varias formas de verificar la normalidad de los datos, entre los diferentes métodos se tienen los numéricos y los gráficos. La falta de normalidad no es un problema severo, pues el ANOVA es robusta a la falta de normalidad. Solo cuando se encuentran valores extremadamente alejados puede haber problemas en las pruebas. La corrección de este problema se hace mediante el uso de: transformaciones, pruebas no paramétricas, modelos lineales generalizados o modelos generalizados usando métodos de cuasi-verosimilitud.

El problema fundamental que ocasiona el no cumplimiento de este supuesto es que las inferencias que se hacen no son válidas. Para detectar no normalidad, lo que en general se usa son contrastes de hipótesis, donde la

hipótesis nula se plantea como la información proviene de una población normal y la alterna es que este supuesto no se cumple.

Algunos estadísticos de prueba para llevar a cabo la comprobación del supuesto de normalidad se presentan a continuación:

6.2.5.1. Prueba de Kolmogorov-Smirnov

Esta es una prueba no paramétrica para variables de tipo continuo o discreto y sirve para contrastar la hipótesis nula H_0 : los datos analizados siguen una distribución M o equivalentemente:

$$H_0 : F_n(w) = F_0(w) \text{ contra } H_a : F_n(w) \neq F_0(w),$$

donde $F_n(w)$ hace referencia a la distribución muestral acumulada observada, $F_0(w)$ es cualquier distribución teórica con la cual se desea contrastar la distribución muestral y $w_1, \dots, w_n$ son los valores observados a los cuales se les quiere aplicar esta prueba.

Características de la prueba:

- i. No hay pérdida de información como en el caso de la prueba ji-cuadrado; en esta todos los valores son incluidos en el desarrollo de la prueba.
- ii. La prueba es conservativa. El valor de α es menor al especificado.
- iii. La prueba es exacta para cualquier tamaño de muestra n , en cambio la prueba de ji-cuadrada es correcta en términos asintóticos (muestras grandes).
- iv. Esta tiene mayor poder que la ji-cuadrada cuando se prueba en contra de varias distribuciones alternativas.
- v. Es difícil aplicarla en distribuciones discretas. Cuando la prueba se utiliza con datos discretos, el investigador debe tener en mente que la probabilidad real de cometer un error tipo I es, cuando mucho, igual al nivel de significación establecido en α .
- vi. La prueba es “moderada” cuando uno o más parámetros deban ser estimados a partir de los datos de la muestra.

La prueba se puede aplicar a los siguientes modelos: normal, exponencial, Weibull, entre otros. En estos casos, se pueden usar los estimadores de los parámetros de dichos modelos.

La metodología para usar esta prueba es la siguiente:

1. Ordene los valores observados $w_1, \dots, w_n$, o sea, $w_{(1)}, \dots, w_{(n)}$ la muestra ordenada.
2. Sea $F_n(w_{(i)}) = i/n$, es decir, la función de distribución muestral en $w_{(i)}$ es igual al número de valores observados menores o iguales a $w_{(i)}$. $F_n(\cdot)$ asigna a cada observación una probabilidad igual a $1/n$.
3. Usando la función de distribución teórica, calcule $F(w_{(1)}), F(w_{(2)}), \dots, F(w_{(n)})$.
4. Determine la distancia más grande entre la función muestral y la teórica

$$D_1 = \sup_w |F_n(w) - F_0(w)|,$$

donde D_1 es el valor “supremo” de la diferencia absoluta entre la frecuencia acumulada observada $F_n(w)$ y la frecuencia acumulada teórica $F_0(w)$, obtenida del modelo. Note que si los valores esperados $F_0(w)$ son similares a los observados $F_n(w)$, entonces la diferencia D_1 es pequeña. Por lo tanto, discrepancias entre el modelo y las observaciones se reflejan en altos valores de D_1 .

Observación 6.8. Se debe tener en cuenta que, al determinar el valor de D_1 , no siempre es suficiente calcular y elegir entre los valores posibles de $|F_n(w) - F_0(w)|$. Esto quiere decir que la distancia vertical más larga entre $F_n(w)$ y $F_0(w)$ posiblemente no ocurra en un valor observado w , sino en algún otro valor de W .

Es posible determinar el valor correcto para D_1 de manera algebraica obteniendo las diferencias $|F_n(w) - F_0(w)|$ para todos los valores de $i = 1, \dots, (r + 1)$, donde r es el número de valores diferentes de w y $F_n(w_0) = 0$. Por lo tanto, para encontrar el valor correcto de la estadística es necesario seleccionar

$$D = \max[\max_{1 \leq i \leq r} (|F_n(w_{(i)}) - F_0(w_{(i)})|), \max_{1 \leq i \leq r} (|F_n(w_{(i-1)}) - F_0(w_{(i)})|)].$$

El valor de D se compara con un valor crítico D_c y con un nivel de significación α . Estos valores críticos dependen del tipo de distribución que se ha supuesto. Existen valores críticos para la distribución normal, exponencial y Weibull, estos se encuentran en Law y Kelton (1991).

Si el modelo que se propone se basa en la distribución normal, entonces D se debe ajustar cuando los parámetros son estimados (es decir, cuando se emplean la media y la varianza muestrales).

La regla de decisión es: el valor de D se compara con un valor de la tabla A.10 $D_n(1 - \alpha)$, si el valor calculado es mayor o igual al de las tablas, se rechaza H_0 .

Ejemplo 6.5. Ordenando los residuales obtenidos al realizar el experimento del ejemplo 5.1 conseguidos en el ejemplo 6.3, se prueba la hipótesis $H_0 : F_n(\hat{\epsilon}) = N(0, 8.72)$ contra $H_a : F_n(\hat{\epsilon}) \neq N(0, 8.72)$, a través del estadístico de prueba propuesto por Kolmogorov-Smirnov.

	$\hat{\epsilon}_{(i)}$	$F_n(\hat{\epsilon}_{(i)})$	$F_0(\hat{\epsilon}_{(i)})$	$ F_n(\hat{\epsilon}_{(i)}) - F_0(\hat{\epsilon}_{(i)}) $	$ F_n(\hat{\epsilon}_{(i-1)}) - F_0(\hat{\epsilon}_{(i)}) $
1	-6.48	0.05	0.014	0.035	0.014
2	-3.62	0.10	0.110	0.010	0.060
3	-2.58	0.15	0.191	0.041	0.091
4	-2.48	0.20	0.200	0.000	0.050
5	-2.18	0.25	0.230	0.019	0.030
6	-1.98	0.30	0.251	0.048	0.001
7	-1.28	0.35	0.332	0.017	0.032
8	-0.82	0.40	0.390	0.009	0.040
9	-0.78	0.45	0.395	0.054	0.004
10	-0.52	0.50	0.430	0.069	0.019
11	-0.48	0.55	0.435	0.114	0.064
12	-0.18	0.60	0.475	0.124	0.074
13	0.72	0.65	0.596	0.053	0.003
14	1.52	0.70	0.696	0.003	0.046
15	1.58	0.75	0.703	0.046	0.003
16	2.92	0.80	0.838	0.038	0.088
17	3.38	0.85	0.873	0.023	0.073
18	3.42	0.90	0.876	0.023	0.026
19	4.52	0.95	0.937	0.012	0.037
20	5.32	1.00	0.964	0.035	0.014

De los resultados obtenidos en la tabla 6.4, se encuentra que

$$D_1 = D = \max(0.124, 0.091) = 0.124$$

En consecuencia, al comparar con $D_{20}(0.95) = 0.294$ no hay evidencias para rechazar la hipótesis de normalidad (valor $p = 0.88$).

6.2.5.2. Prueba de Shapiro-Wilk

Dada una muestra aleatoria simple de tamaño n , sea $(w_1, \dots, w_n)$, se quiere saber si proviene de una población con distribución normal. Este problema es muy frecuente, ya que son muchas las pruebas de inferencia estadística que

exigen como condición imprescindible para su aplicabilidad que la población de procedencia de la información sea normal.

La hipótesis nula de interés es H_0 : la muestra procede de una población normal.

En el desarrollo del test de normalidad propuesto por (Shapiro y Wilk 1965), se deben tener en cuenta los siguientes pasos:

1. Se ordena la muestra de menor a mayor, al igual que en la prueba anterior, se obtiene el nuevo vector muestral $(w_{(1)}, \dots, w_{(n)})$ siendo $w_{(i)}$ el i -ésimo valor de la muestra ordenada.
2. Se calcula el estadístico:

$$W_c = \frac{1}{ns^2} \left(\sum_{i=1}^h a_{in} (w_{(n-i+1)} - w_{(i)}) \right)^2,$$

siendo s^2 una estimación de la varianza poblacional

$$h = \begin{cases} \frac{n}{2}, & \text{si } n \text{ par} \\ \frac{n-1}{2}, & \text{si } n \text{ impar.} \end{cases}$$

y a_{in} es un valor tabulado.

3. La distribución del estadístico W se encuentra también tabulada para cada nivel de significación.

Si W_c es menor o igual que $W_n(\alpha)$, entonces se rechaza la hipótesis de normalidad.

6.2.5.3. Contraste de Jarque - Bera

El contraste de Jarque y Bera (1987) utiliza las dos principales características de la distribución normal: la simetría y el apuntamiento, usando estas dos características se busca determinar si la distribución de donde proceden los datos es o no normal.

Sea $F_n(w)$ la distribución de los datos, $w_1, \dots, w_n$, a este conjunto de datos se les quiere aplicar esta prueba. Para el caso de interés son los residuales obtenidos del ajuste del modelo propuesto.

$$\begin{aligned} H_0 : F_n(w) &= N(\mu_0, \sigma_0^2) \\ H_a : F_n(w) &\neq N(\mu_0, \sigma_0^2) \end{aligned}$$

La estadística de prueba es

$$\tau = \frac{n - (k + 1)}{6} \left[r_1^2 + \frac{1}{4}(r_2 - 3)^2 \right],$$

donde $(k + 1)$ es el número de parámetros del modelo, r_1 y r_2 son los coeficientes de asimetría y de apuntamiento (curtosis) de $F_n(w)$ estimados, respectivamente. Bajo la hipótesis nula $\tau \sim \chi^2_{(2)}$, la hipótesis nula se rechaza si $\tau \geq \chi^2_{(2, 1-\alpha)}$.

Ejemplo 6.6. Retomando los residuales obtenidos del ejemplo 6.3, se ilustraran a continuación las pruebas de normalidad presentadas anteriormente.

a. Shapiro-Wilk

$$W_c = 0.976$$

Como $W_c = 0.976 > W_{20}(0.05) = 0.905$ y $P(W_c < 0.976) = 0.86$, no se rechaza la hipótesis de normalidad.

b. Contraste de Jarque - Bera

$$\tau = \frac{20 - 4}{6} \left[(-0.04)^2 + \frac{1}{4}(-0.09 - 3)^2 \right] = 6.39$$

al comparar con una $\chi^2_{(2, 0.05)} = 5.99$, la hipótesis de normalidad de los residuales se rechaza, encontrándose un resultado diferente al de las otras dos pruebas. Sin embargo, según Pachón (2003), esta no es igual de potente a la prueba de Shapiro-Wilk para el caso de muestras pequeñas.

6.2.6. Pruebas de no aditividad

Puede suceder que el modelo aditivo no sea adecuado para describir el ensayo. La escogencia de un modelo aditivo o no depende de la naturaleza del experimento; la experiencia es la mejor guía para la decisión sobre uno u otro modelo.

Cuando el experimento se hace en cuadros latinos, cuadros grecolatinos, series de cuadros ortogonales o en experimentos cruzados con una observación por celda, arbitrariamente se postula un modelo como aditivo (se supone que las interacciones son nulas), ya que no es posible realizar pruebas de hipótesis sobre interacciones.

Para evaluar si el modelo es o no aditivo, se hace uso de la prueba de no aditividad propuesta por Tukey, la cual se describe a continuación.

6.2.6.1. Contraste de Tukey de no aditividad

Para ilustrar el prueba se parte del modelo cruzado

$$y_{ij} = \mu + A_i + B_j + AB_{ij} + \epsilon_{ij}, \quad i = 1, \dots, a, \quad j = 1, \dots, b \quad (6.1)$$

Se supone además que $\epsilon_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$ y se imponen las restricciones

$$\sum_{i=1}^a A_i = \sum_{j=1}^b B_j = \sum_{i=1}^a AB_{ij} = \sum_{j=1}^b AB_{ij} = 0.$$

El interés es probar la hipótesis

$$H_0 : AB_{11} = \dots = AB_{1b} = \dots = AB_{a1} = \dots = AB_{ab} = 0.$$

Tukey impuso una restricción conveniente sobre la interacción AB_{ij} al asumir que el efecto de la interacción para cada celda es una función de los efectos principales según un polinomio de segundo grado, es decir,

$$AB_{ij} = \alpha_0 + \alpha_1 A_i + \beta_1 B_j + \alpha_2 A_i^2 + \gamma_1 A_i B_j + \beta_2 B_j^2, \quad (6.2)$$

donde $\alpha_0, \alpha_1, \alpha_2, \beta_1, \beta_2, \gamma_1$ y γ_2 son constantes.

Promediando sobre j la ecuación (6.2), se tiene

$$\overline{AB}_{i.} = \frac{1}{b} \sum_{j=1}^b AB_{ij},$$

$$\overline{AB}_{i.} = \alpha_0 + \alpha_1 A_i + \frac{\beta_1}{b} \sum_{j=1}^b B_j + \alpha_2 A_i^2 + \frac{\gamma_1}{b} A_i \sum_{j=1}^b B_j + \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 \quad (6.3)$$

y, ahora sobre i ,

$$\overline{AB}_{.j} = \alpha_0 + \frac{\alpha_1}{a} \sum_{i=1}^a A_i + \beta_1 B_j + \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2 + \frac{\gamma_1}{a} B_j \sum_{i=1}^a A_i + \beta_2 B_j^2. \quad (6.4)$$

Por las restricciones impuestas, (6.3) y (6.4) pueden simplificarse como

$$\overline{AB}_{i.} = \alpha_0 + \alpha_1 A_i + \alpha_2 A_i^2 + \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 = 0$$

$$\overline{AB}_{.j} = \alpha_0 + \beta_1 B_j + \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2 + \beta_2 B_j^2 = 0$$

Por lo tanto,

$$\alpha_1 A_i + \alpha_2 A_i^2 = -\alpha_0 - \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 \quad (6.5)$$

$$\beta_1 B_j + \beta_2 B_j^2 = -\alpha_0 - \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2. \quad (6.6)$$

Sustituyendo (6.5) y (6.6) en (6.2) se encuentra

$$AB_{ij} = -\alpha_0 - \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2 - \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 + \gamma A_i B_j. \quad (6.7)$$

Pero

$$\begin{aligned} \overline{AB}_{i.} &= \frac{1}{b} \sum_{j=1}^b AB_{ij} = \frac{1}{b} \sum_{j=1}^b \left(-\alpha_0 - \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2 - \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 + \gamma A_i B_j \right) \\ &= -\alpha_0 - \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2 - \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 + \gamma \frac{A_i}{b} \sum_{j=1}^b B_j \\ &= -\alpha_0 - \frac{\alpha_2}{a} \sum_{i=1}^a A_i^2 - \frac{\beta_2}{b} \sum_{j=1}^b B_j^2 = 0. \end{aligned}$$

Debido al hecho que $\sum_{j=1}^b B_j = 0$ y $\sum_{j=1}^b AB_{ij} = 0$, entonces (6.7) se reduce a

$$AB_{ij} = \gamma A_i B_j \quad (6.8)$$

Sustituyendo (6.8) en (6.1), se obtiene el nuevo modelo

$$y_{ij} = \mu + A_i + B_j + \gamma A_i B_j + \epsilon_{ij}. \quad (6.9)$$

Al imponer las restricciones $\sum_{i=1}^a A_i = 0$ y $\sum_{j=1}^b B_j = 0$, se tiene la hipótesis $H_0 : \gamma = 0$.

Para obtener una estadística de prueba, se tiene inicialmente los estimadores de mínimos cuadrados del modelo en (6.9), es decir,

$$Q = \sum_i \sum_j \epsilon_{ij}^2 = \sum_i \sum_j (y_{ij} - \mu - A_i - B_j - \gamma A_i B_j)^2$$

Al derivar Q con respecto a γ e igualar a cero, se tiene las ecuaciones

$$\begin{aligned} \sum_i \sum_j A_i B_j y_{ij} - \mu \sum_i \sum_j A_i B_j - \sum_i \sum_j A_i^2 B_j \\ - \sum_i \sum_j A_i B_j^2 - \gamma \sum_i \sum_j A_i^2 B_j^2 = 0. \end{aligned}$$

Por las restricciones impuestas a $\sum_i \sum_j A_i B_j = \sum_i \sum_j A_i^2 B_j = \sum_i \sum_j A_i B_j^2 = 0$, se tiene que

$$\sum_i \sum_j A_i B_j y_{ij} = \gamma \sum_i \sum_j A_i^2 B_j^2.$$

Por lo tanto,

$$\hat{\gamma} = \frac{\sum_i \sum_j A_i B_j y_{ij}}{\sum_i \sum_j A_i^2 B_j^2}. \quad (6.10)$$

La definición natural para la suma de cuadrados de la interacción es

$$\sum_i \sum_j (\hat{\gamma} A_i B_j)^2 = \hat{\gamma}^2 \sum_i A_i^2 \sum_j B_j^2.$$

Sustituyendo en (6.10), se obtiene

$$SCNA = \frac{\left(\sum_i \sum_j A_i B_j y_{ij} \right)^2}{\sum_i \sum_j A_i^2 B_j^2}.$$

Como A_i y B_j son desconocidos, se estiman a partir del modelo (6.1) como $\hat{A}_i = \bar{y}_{i.} - \bar{y}_{..}$ y $\hat{B}_j = \bar{y}_{.j} - \bar{y}_{..}$, luego la suma de cuadrados de no aditividad es

$$SCNA = \frac{\left[\sum_i \sum_j (\bar{y}_{i.} - \bar{y}_{..})(\bar{y}_{.j} - \bar{y}_{..}) y_{ij} \right]^2}{\sum_i \sum_j (\bar{y}_{i.} - \bar{y}_{..})^2 (\bar{y}_{.j} - \bar{y}_{..})^2}. \quad (6.11)$$

Para la construcción del estadístico de prueba, se postula el siguiente teorema.

Teorema 6.1. Sea $SCE = \sum_i \sum_j (y_{ij} - \bar{y}_{i.} - \bar{y}_{.j} + \bar{y}_{..})^2$ en el modelo (6.1). Entonces, la suma de cuadrados de residuales en (6.11) es:

$$SCE(Nuevo) = SCE - SCNA.$$

Bajo $H_0 : \gamma = 0$ cierta, entonces $\frac{SCE}{\sigma^2}$ y $\frac{SCE(Nuevo)}{\sigma^2}$ se distribuyen de forma independiente como una chi-cuadrado. Por consiguiente, el cociente

$$F = \frac{SCNA}{\frac{SCE(Nuevo)}{ab-a-b}} \sim F_{(1, ab-a-b)}.$$

La prueba de este teorema puede verse en Rao (1973).

Cuando se tengan tres factores, la suma de cuadrados de no aditividad es obtenida como

$$\frac{\left[\sum_i \sum_j \sum_k (\bar{y}_{i..} - \bar{y}_{...})(\bar{y}_{.j.} - \bar{y}_{...})(\bar{y}_{..k} - \bar{y}_{...})y_{ijk} \right]^2}{\sum_i \sum_j \sum_k (\bar{y}_{i..} - \bar{y}_{...})^2 (\bar{y}_{.j.} - \bar{y}_{...})^2 (\bar{y}_{..k} - \bar{y}_{...})^2}.$$

El desarrollo de la prueba puede verse en Tukey (1949).

Ejemplo 6.7. Retomando los datos del ejemplo 3.7, se probará la hipótesis de no aditividad $H_0 : \gamma = 0$.

Para este caso, se obtuvo $SCE = 2.07$ y se encuentra que

$$\hat{\gamma} = \frac{(0.28)(0.05)(3.5) + \dots + (-0.95)(0.3)(2.5)}{(0.34)(2.86)} = \frac{-1.07}{0.97} = -1.10.$$

La suma de cuadrados de la no aditividad es

$$SCNA = \frac{(-1.07)^2}{0.97} = 1.18.$$

Por consiguiente, la suma de cuadrados de residuales es

$$SCE(Nuevo) = 2.07 - 1.18 = 0.89.$$

Como

$$F = \frac{1.18}{\frac{0.89}{11}} = 14.59$$

es mayor que $F_{(1,11,0.05)} = 4.84$, hay problemas de no aditividad en el modelo planteado. Por lo tanto, para un experimento futuro se recomendaría tener en cuenta la interacción entre los dos factores y realizar una mayor cantidad de replicaciones.

6.3. Solución a los problemas de no homocedasticidad y no normalidad

Las siguientes son algunas de las estrategias para solucionar los diferentes problemas en el ajuste del modelo propuesto.

6.3.1. Uso de transformaciones

Transformar significa un cambio de métrica de la variable original por una medida en otra escala. La transformación tiene como idea central que si en la variable original los supuestos no son adecuados, puede existir una transformación conveniente tal que en la nueva métrica estos se satisfagan.

Entre 1936 y 1940 fueron publicados algunos artículos sobre la transformación raíz cuadrada, logaritmo natural y transformación angular aplicables en el análisis de varianza. En 1954 surgen algunas publicaciones sobre el uso de las transformaciones; en particular, cabe citar los trabajos de Moore-Tukey y Anscombe-Tukey, quienes desarrollaron una familia de transformaciones. Box y Cox (1964) publicaron un artículo que es considerado como un gran marco de trabajo para la obtención de las transformaciones.

6.3.1.1. Consideraciones generales sobre transformaciones

En análisis de varianza y regresión las transformaciones pueden ser aplicadas para:

- i) Linealizar el modelo.
- ii) Corregir desvíos de los supuestos del modelo.
- iii) Simplificar el modelo.

En la tabla 6.6 se presentan algunas transformaciones para linealizar el modelo.

Tabla 6.6: Transformaciones que linealizan el modelo

	Modelo	Transformación
Exponencial	$Y = \beta_0 e^{\beta_1 X} \epsilon$	$\ln Y = \ln \beta_0 + \beta_1 X + \ln \epsilon$
Potencia	$Y = \beta_0 X^{\beta_1} \epsilon$	$\ln Y = \ln \beta_0 + \beta_1 \ln X + \ln \epsilon$
Multiplicativo	$Y = \beta_0 X_1^{\beta_1} X_2^{\beta_2} \epsilon$	$\ln Y = \ln \beta_0 + \beta_1 \ln X_1 + \beta_2 \ln X_2 + \ln \epsilon$
Recíproco	$Y = \frac{1}{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon}$	$\frac{1}{Y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon$
Logístico	$Y = \frac{1}{1 + \exp[-(\beta_0 + \beta_1 X + \epsilon)]}$	$\log\left(\frac{Y}{1-Y}\right) = \beta_0 + \beta_1 X + \epsilon$
Raíz	$Y = \sqrt[k]{X\beta + \epsilon}$	$Y^k = X\beta + \epsilon$

6.3.2. Uso de las transformaciones para estabilizar varianza

Si el supuesto de homogeneidad de varianza no es satisfecho, puede suceder que una transformación de la variable dependiente estabilice la varianza.

Bartlett (1947) y Siqueira (1983) determinan una transformación conveniente en caso de que exista una relación entre $E(Y) = \mu$ y $Var(Y) = \sigma^2$, es decir,

$$\sigma^2 = F(\mu) \quad (6.12)$$

La idea ahora es buscar la transformación de Y , por ejemplo, $Z = g(Y)$ tal que $Var(Z) = constante = K$.

Desarrollando $g(Y)$ en series de Taylor, se tiene

$$Z = g(Y) = g(\mu) + (Y - \mu)g'(\mu). \quad (6.13)$$

Tomando valor esperado y varianza de la nueva variable Z , se llega a

$$\begin{aligned} E(Z) &= E[g(\mu) + (Y - \mu)g'(\mu)] = g(\mu) \\ Var(Z) &= E[Z - E(Z)]^2 = E[(Y - \mu)g'(\mu)]^2 \\ &= [g'(\mu)]^2 Var(Y). \end{aligned} \quad (6.14)$$

Haciendo $Var(Z) = K$ y $Var(Y) = F(\mu)$, se llega en la anterior expresión a

$$[g'(\mu)]^2 F(\mu) = K,$$

y despejando $g'(\mu)$, se sigue que

$$g'(\mu) = \sqrt{\frac{K}{F(\mu)}}$$

y, entonces,

$$g(\mu) = \int \sqrt{\frac{K}{F(\mu)}} d\mu. \quad (6.15)$$

De forma general, se tiene que

$$g(Y) = \int \sqrt{\frac{K}{F(Y)}} dY. \quad (6.16)$$

Con la expresión (6.16), se determina la forma genérica de la transformación que estabiliza la varianza.

A continuación se presentan algunos ejemplos en los cuales se evidencia el anterior problema.

Ejemplo 6.8.

i. Si $Y \sim P(\mu)$, entonces $Var(Y) = F(\mu) = \mu$. Luego,

$$g(\mu) = \int \sqrt{\frac{K}{\mu}} d\mu = K_1 \sqrt{\mu} + K_2$$

no es constante. Pero al transformar haciendo $Z = \sqrt{Y}$ se estabiliza la varianza, puesto que

$$\begin{aligned} Var(Z) &= [g'(\mu)]^2 Var(Y) \\ &= \left(\frac{K_1}{2\sqrt{\mu}} \right)^2 \mu = \frac{K_1^2}{4} \end{aligned}$$

es una constante.

ii. Suponga ahora que Y es una variable aleatoria tal que $Var(Y) = F(\mu) = \mu^2$, entonces

$$g(\mu) = \int \sqrt{\frac{K}{\mu^2}} d\mu = K_1 \ln(\mu) + K_2.$$

Por lo tanto, la transformación $Z = \ln Y$ estabiliza la varianza, puesto que $Var(Z) = [g'(\mu)]^2 Var(Y) = K_1^2$.

iii. Suponga $Y^* \sim B(n, \mu)$, y si $Y = \frac{Y^*}{n}$ es la proporción de éxitos, entonces $Var(Y) = F(\mu) = \frac{\mu(1-\mu)}{n}$, luego la transformación

$$g(\mu) = \int \frac{\sqrt{nK}}{\sqrt{\mu(1-\mu)}} d\mu = K_1 \arccos(\sqrt{\mu}) + K_2$$

De este modo, la transformación $Z = \arccos(\sqrt{Y})$ estabiliza la varianza, ya que satisface

$$Var(Z) = [g'(\mu)]^2 Var(Y) = \left(\frac{K_1}{2\sqrt{\mu(1-\mu)}} \right)^2 \frac{\mu(1-\mu)}{n} = \frac{K_1^2}{4n},$$

constante siempre que n sea constante.

La tabla 6.7, tomada de Bartlett (1947), resume algunas transformaciones cuando las varianzas y las medias están relacionadas.

Observación 6.9. En la práctica, para ver la relación entre σ^2 y μ , se debe construir un gráfico de S_i^2 en función de $\bar{Y}_i$ o también entre $\log(S_i^2)$ y $\log(\bar{Y}_i)$ para indicar la relación existente.

Las soluciones (transformaciones) dependen del comportamiento que se observe en los residuales, es decir, de los supuestos que se hagan del comportamiento de la varianza.

Tabla 6.7: Transformaciones recomendadas por Bartlett (1947) cuando hay relación entre media y varianza

Rel. var. media	Transformación	Var. nueva escala	Distribución
μ	$\sqrt{Y}$ o $\sqrt{Y+1}$	0.25	Poisson
$K^2\mu$	$\sqrt{Y}$	$0.25K^2$	Poisson
$\frac{2\mu^2}{n-1}$	$\log Y$	$\frac{2}{n-1}$	Varianzas M
$K^2\mu^2$	$\log Y$ o $\log(Y+1)$	K^2	Empírica
$\frac{\mu(1-\mu)}{n}$	$\arccos(\sqrt{Y})$	$\frac{0.25}{n}$	Binomial
$K^2\mu^2(1-\mu)^2$	$\log\left(\frac{Y}{1-Y}\right)$	K^2	Empírica
$\frac{(1-\mu^2)^2}{n-1}$	$\frac{1}{2}\log\left(\frac{1+Y}{1-Y}\right)$	$\frac{1}{n-3}$	Correlación
$\mu + K^2\mu^2$	$\frac{1}{k}\operatorname{arccosh}(k\sqrt{Y})$	0.25	Binomial neg.
μ^4	$\frac{1}{Y}$	1	Empírica

6.3.3. Uso de transformaciones para corregir no normalidad

Desvíos moderados a la falta de normalidad no afectan los resultados de las estadísticas t y F , pero si la distribución presenta una asimetría acentuada, el coeficiente de asimetría difiere ampliamente de cero y ocurre algún desvío grande en la región de las observaciones extremas, los métodos estadísticos que suponen normalidad no deben emplearse. En estos casos, es posible encontrar una transformación que lleve a una distribución razonablemente simétrica.

Ejemplo 6.9. En *Bhattacharya y Johnson (1977)* se presenta el conjunto de datos de la tabla 6.8.

Tabla 6.8: Datos sin y con transformación de la variable dependiente

Y					$Z = Y^{1/4}$				
39.3	14.8	6.3	0.9	6.5	2.5	1.96	1.58	0.97	1.60
3.5	8.3	10	1.3	7.1	1.37	1.70	1.78	1.07	1.63
6.0	17.1	16.8	0.7	7.9	1.57	2.03	2.02	0.91	1.68
2.7	26.2	24.3	17.7	3.2	1.29	2.26	2.22	2.05	1.34
7.4	6.6	5.2	8.3	5.9	1.64	1.60	1.51	1.70	1.56
3.5	8.3	44.8	8.3	13.4	1.37	1.70	2.59	1.70	1.91
19.4	19.0	14.1	1.9	12.0	2.07	2.10	1.93	1.17	1.86
19.7	10.3	3.4	16.7	4.3	2.11	1.79	1.36	2.02	1.44
1.0	7.6	28.3	26.2	31.7	1.0	1.66	2.31	2.26	2.31
8.7	18.9	3.4	10.0		1.72	2.09	1.36	1.78	

En este caso, al trabajar con la variable Y y probar la hipótesis de normalidad, se encuentra, según los resultados de los estadísticos de prueba de Kolmogorov y Shapiro:

Prueba	Estadístico	valor p
Shapiro-Wilk	$W=0.87$	< 0.0001
Kolmogorov-Smirnov	$D=0.18$	< 0.0100

A partir de los anteriores resultados, se rechaza la hipótesis de normalidad a través tanto del estadístico de Shapiro-Wilk (valor $p < 0.0001$) como el de Kolmogorov-Smirnov (valor $p < 0.0100$), con lo cual se evidencia que se debe transformar esta variable.

Al realizar la transformación $Z = Y^{1/4}$ se satisface el supuesto de normalidad que se evidencia, según los resultados de las pruebas estadísticas obtenida,s en la siguiente tabla:

Prueba	Estadístico	valor p
Shapiro-Wilk	$W=0.98$	0.8099
Kolmogorov-Smirnov	$D=0.07$	> 0.1500

En la gráfica que se presenta en la figura 6.2, nótese que en la gráfica 6.2(b) se satisface la normalidad al realizar esta transformación, mientras que en la gráfica 6.2(a) no se cumple este supuesto.




Figura 6.2: Histogramas de la variable sin transformar (a) y transformada (b).

Existen trabajos teóricos que tratan el problema de escoger las transformaciones, pero no existen métodos prácticos que indiquen la transformación adecuada. En la práctica, se sugiere la transformación $\sqrt{Y}$, $\sqrt[4]{Y}$, $\ln Y$, $\frac{1}{Y}$ para disminuir valores grandes, en tanto que Y^2 y Y^3 tienden a aumentar valores pequeños.

A continuación se presenta una transformación que permite estabilizar varianza y corregir, a la vez, el problema de no normalidad.

6.3.4. Transformación de Box - Cox

El objetivo de esta transformación es homogeneizar la varianza. En la mayoría de los casos al cumplirse este objetivo se está corrigiendo de una vez el problema de falta de normalidad.

Esta transformación tiene como supuesto que la varianza es una función de la media, $\sigma_t^2 = f(\mu_t)$. Por lo tanto, la metodología tiene como objetivo buscar un valor para λ tal que $\sigma_t / \mu_t^{1-\lambda} = \text{constante}$.

La transformación se hace sobre la variable dependiente y tiene la siguiente estructura general:

$$T(y) = \begin{cases} y^\lambda & \text{si } \lambda \neq 0 \\ \ln y & \text{si } \lambda = 0 \end{cases}$$

Para hacer uso de la transformación de deben tener en cuenta los siguientes pasos:

1. Se dividen las n observaciones en H grupos, cada uno con igual número observaciones. *Ejemplo:* si se tiene 125 observaciones y se quieren 7 grupos, cada uno tendrá 17 observaciones ($125/7=17$). Se dejan por fuera las 6 primeras o últimas observaciones. Cada grupo tendrá $(n - h)/H$ observaciones, con h el número de observaciones que se dejan por fuera de la clasificación inicial.
2. En cada grupo se calcula la media y la desviación estándar, es decir, se obtiene $\{\bar{y}_1, s_1\}, \{\bar{y}_2, s_2\}, \dots, \{\bar{y}_H, s_H\}$.
3. Para cada λ se calculan los coeficientes de variación presentados en la tabla 6.9. En dicha tabla, $CV(.) = \text{Coeficiente de Variación} = \frac{DS(\lambda)}{\mu(\lambda)}$, con

$$\mu(\lambda) = \frac{1}{H} \sum_{i=1}^H \frac{s_i}{\bar{y}_i^{1-\lambda}}$$

$$DS(\lambda) = \sqrt{\frac{1}{H-1} \sum_{i=1}^H \left[\frac{s_i}{\bar{y}_i^{1-\lambda}} - \mu(\lambda) \right]^2}$$

El λ que se escoge para realizar la transformación es aquel con menor coeficiente de variación.

Tabla 6.9: Transformación de la variable dependiente a través de la escogencia de λ .

Grupo	Potencia (λ)				
	-1	-0.5	0	0.5	1
1	$s_1/\bar{y}_1^2$	$s_1/\bar{y}_1^{1.5}$	$s_1/\bar{y}_1$	$s_1/\bar{y}_1^{0.5}$	s_1
2	$s_2/\bar{y}_2^2$	$s_2/\bar{y}_2^{1.5}$	$s_2/\bar{y}_2$	$s_2/\bar{y}_2^{0.5}$	s_2
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
H	$s_H/\bar{y}_H^2$	$s_H/\bar{y}_H^{1.5}$	$s_H/\bar{y}_H$	$s_H/\bar{y}_H^{0.5}$	s_H
Coeficiente	CV(-1)	CV(-0.5)	CV(0)	CV(0.5)	CV(1)

6.4. Implementación en SAS

A partir de los datos del ejemplo 5.1, se presenta a continuación el programa en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos 6.1, 6.2, 6.3, 6.4, 6.5 y 6.6 del presente capítulo.

```

OPTIONS NODATE NONUMBER;
/*Para que en la salida no aparezca fecha ni paginación*/
/* Diseño completamente aleatorizado de efectos fijos */
DATA EJEMPLO61;

/*Datos de las dietas en un DCA. Ejemplo 5.1*/
SET EJEMPLO51;
PROC GLM DATA=EJEMPLO61;
CLASS DIETA;
MODEL DIFPESO=DIETA;
OUTPUT OUT=RESI R=RESID STUDENT=STRESID;

/*Se guardan los residuales y los residuales estudentizados
en el archivo RESI*/
MEANS DIETA/BON DUNCAN DUNNETT LSD SCHEFFE SNK T TUKEY;

*Se obtienen las diferentes pruebas de comparaciones
múltiples o pruebas no planeadas*/
/*Contrastes ortogonales o contrastes planeados*/
CONTRAST 'ENTRE DIETAS' DIETA 1 1 -1 -1,
DIETA 1 -1 0 0,
DIETA 0 0 1 -1;

/*Obtención de las pruebas de normalidad y gráfico de probabilidad normal*/
PROC UNIVARIATE DATA=RESI NORMAL PLOT;

/*Con la opción NORMAL se muestran las pruebas de
normalidad y con PLOT el gráfico de probabilidad normal */

```

```

VAR RESID;
QQPLOT RESID;

/*Se presenta el gráfico QQPLOT*/
/*Obtención de las pruebas de homocedasticidad*/
PROC GLM DATA=RESI;
CLASS DIETA;
MODEL RESID=DIETA;
MEANS DIETA/HOVTTEST=LEVENE (TYPE=ABS) HOVTTEST=BARTLETT;

/*Se obtienen las pruebas de LEVENE y BARTLETT para
homocedasticidad de los residuos agrupados por DIETA*/
\noindent RUN;

```

6.5. Implementación en R

A partir de los datos del ejemplo 5.1, se presentan a continuación los programas en el software estadístico R de los ejemplos 6.1, 6.2, 6.3, 6.4, 6.5, 6.6 y 6.9.

```

#####
## Ejemplo 6.1 ##
#####

#Introducción de los datos del ejemplo
ejemplo6.1 <- data.frame(dieta=factor(rep(seq(1,4),5)),
replica=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4),rep(5,4))),
difpeso=c(-9.3,-10.1,1.5,-3.2,2.5,-5.0,-2.0,-5.6,-5.4,-7.2,
-0.5,-8.4,-3.6,-9.2,3.4,-5.3,1.7,-8.1,-2.5,-1.4))

anova6.1<-lm(difpeso~dieta,contrasts=list(dieta="contr.sum"),data=ejemplo6.1)
summary(anova6.1)
summary(aov(anova6.1))

# desviación estándar de los residuales
sd <- sd(anova6.1$residuals)
# Residuales estudentizados
estresiduals <- anova6.1$residuals/sd
# Concatena los dos vectores de residuales y residuales estudentizados
resi <- cbind(anova6.1$residuals,estresiduals)
# Nombra las columnas correspondientes
colnames(resi) <- c("Resid", "Resid.Est")

# pruebas de comparaciones múltiples

library(agricolae)
# Prueba de Bonferroni

```

```

pairwise.t.test(ejemplo6.1$difpeso,ejemplo6.1$dieta, p.adj = "bonf")

# Prueba de Duncan
duncan.test(anova6.1,"dieta", group=TRUE,console=TRUE,main="Dieta")

# Prueba de Dunnett
library(multcomp)
dunnett <- glht(anova6.1, linfct = mcp(dieta = "Dunnett"))
confint(dunnett, level = 0.95)

# Prueba LSD de Fisher
LSD.test(anova6.1,"dieta", group=TRUE,console=TRUE,main="Dieta")

# Prueba de Scheffe
scheffe.test(anova6.1,"dieta",group=TRUE,console=TRUE,main="Dieta")

# Prueba SNK (Student-Newman-Keuls)
SNK.test(anova6.1,"dieta",group=TRUE,console=TRUE,main="Dieta")

# Prueba de Tukey
TukeyHSD(aov(anova6.1),"dieta",conf.level = 0.95)
plot(TukeyHSD(aov(anova6.1),"dieta",conf.level = 0.95))

# Comparaciones planeadas (tabla de ANOVA) ejemplo de las dieta

contrastes <- matrix(c(0,0,1,-1,1,1,-1,-1,1,-1, 0,0),4,3)
# 4 Dietas con 3 contrastes ortogonales
colnames(contrastes)<-c("miu3-miu4=C1","miu1+miu2-miu3-miu4=C2",
"miu1-miu2=C3") # nombres para los contrastes
contrasts(ejemplo6.1$dieta)<-contrastes
dca3=anova6.1
dca3$contrasts #correr primero el modelo
summary.aov(dca3,split=list(dieta=list(C1=1,C2=2,C3=3)))

#####
## Ejemplo 6.2 ##
#####

# Gráficos exploratorios de los residuales

# Histograma de los residuales
hist(anova6.1$residuals, main = "Histograma de los Residuales", axes = TRUE,
breaks = "Sturges", col=4)
# Box plot por dietas
boxplot(difpeso~dieta,data=ejemplo6.1, main="Diferencia de pesos por dietas",
xlab="dieta", ylab="diferencia de peso",col=4)
# Box plot de los residuales del modelo
boxplot(anova6.1$residuals,main="Residuales del modelo",col=4)

```

```

# Gráficos de validación de supuestos sobre residuales
x11()
split.screen(c(2,2))
screen(1)
plot(anova6.1$fitted.values,anova6.1$residuals,main="Residuals vs. Fitted",
pch=20)
# gráfico de residuales vs valores ajustados
abline(h=0,lty=2)
screen(2)
plot(ejemplo6.1$dieta,anova6.1$residuals,main="Residuals vs. Levels")
# gráfico de residuales vs niveles de tratamientos
screen(3)
plot(1:20,anova6.1$residuals, main="Residuals vs. time order",pch=20)
# gráfico de residuales vs valores en el tiempo
abline(h=0,lty=2)
screen(4)
# gráfico de residuales Q-Q
qqnorm(anova6.1$residuals,pch=20)
# línea de probabilidad normal gráfico de residuales Q-Q
qqline(anova6.1$residuals)
# Gráfico Q-Q con bandas de confianza
library(car)
qqPlot(anova6.1$residuals)
# Todos los gráficos clásicos en uno
par(mfrow=c(2,2))
plot(anova6.1)

#####
## Ejemplo 6.3 ##
#####

# Test de homocedasticidad o Homogeneidad de varianzas Bartlett
bartlett.test(anova6.1$residuals~dieta,data=ejemplo6.1)

#####
## Ejemplo 6.4 ##
#####

# librería para la prueba de Levene
library(lawstat)
# librería para poder hacer la prueba de LEVENE
library(car)
# librería para la prueba de Levene requerida
library(VGAM)

# Test de homocedasticidad o homogeneidad de varianzas Levene
levne.test(anova6.1$residuals, ejemplo6.1$dieta)
levneTest(anova6.1$residuals~dieta,center=median,data=ejemplo6.1)
levneTest(anova6.1$residuals~dieta,center=mean,data=ejemplo6.1)

```



```
#####
## Ejemplo 6.5 ##
#####
```

```
# Prueba de normalidad de Kolmogorov-Smirnov
n.q <- (anova6.1$residuals-mean(anova6.1$residuals))/sd(anova6.1$residuals)
# Lista con las posiciones de los datos ordenados
n.o <- order(n.q)
# Vector de cuantiles estandarizados y ordenados.
n.qo <- n.q[n.o]
# Prueba K-S para saber si los datos provienen de una normal
ks.test(n.qo, pnorm)
# forma alternativa para el test de K-S
ks.test(anova6.1$residuals,"pnorm",mean(anova6.1$residuals),
sd(anova6.1$residuals))
```

```
#####
## Ejemplo 6.6 ##
#####
```

```
# Prueba de normalidad de Shapiro-Wilk
shapiro.test(anova6.1$residuals)
```

```
# Prueba de normalidad de Jarque-Bera
library(tseries)
jarque.bera.test(anova6.1$residuals)
```

```
# Prueba de normalidad de Anderson-Darling
library(nortest)
ad.test(anova6.1$residuals)
# Prueba de normalidad de Cramer-von Mises
cvm.test(anova6.1$residuals)
# Prueba de normalidad de Lilliefors
lillie.test(anova6.1$residuals)
```

```
## Gráfico de probabilidad normal
plot(density(anova6.1$residuals),main="Gráfico de Probabilidad Normal")
```

```
#####
## Ejemplo 6.9 ##
#####
```

```
ejemplo6.9<-c(39.3,3.5,6.0,2.7,7.4,3.5,19.4,19.7,1.0,8.7,14.8,8.3,17.1,
26.2,6.6,8.3,19.0,10.3,7.6,18.9,6.3,10,16.8,24.3,5.2,44.8,14.1,3.4,28.3,
3.4,0.9,1.3,0.7,17.7,8.3,8.3,1.9,16.7,26.2,10.0,6.5,7.1,7.9,3.2,5.9,13.4,
12.0,4.3,31.7)
# Verificación de normalidad con los datos originales
ks.test(ejemplo6.9, "pnorm", mean(ejemplo6.9), sd(ejemplo6.9))
shapiro.test(ejemplo6.9)
```

```
# datos transformados con la potencia Z=Y^1/4
Z<-ejemplo6.9^(1/4)

# Verificación de normalidad con los datos transformados
ks.test(Z, "pnorm", mean(Z), sd(Z))
shapiro.test(Z)
```

6.6. Ejercicios

1. Considere los datos y el análisis del ejercicio 6 del capítulo 5. Analice los residuos de este experimento gráficamente y a través de las pruebas estadísticas pertinentes. ¿Se satisfacen los supuestos del análisis de varianza?
2. Considere los datos y el análisis del ejercicio 10 del capítulo 5.
 - a. Analice los residuos de este experimento. ¿Se satisfacen los supuestos del análisis de varianza?
 - b. En caso de no cumplirse alguno de los supuestos del análisis de varianza, proponga una transformación apropiada, realice de nuevo el análisis de varianza y concluya.
3. Determine la linealidad o no de los siguientes modelos justificando su respuesta. En todos los casos X_i y X_{ji} son conocidas.
 - a. $Y_i = \beta_0 + \beta_1 X_i + \beta_2^2 (\log X_i)^2 + d_i$.
 - b. $Y_i = \beta_0 \exp(-\beta_1 X_{1i}) (X_{2i} + \beta_2) + d_i$.
 - c. $Y_i = \frac{1}{\beta_0^2} \exp(-\beta_1 X_{1i}) \left(X_{2i}^{\beta_2 X_{3i} + \beta_4} \right)$.
 - d. $Y_i = \beta_1 + \beta_0 \beta_1 X_{1i} + \beta_2 X_{2i} + d_i$.
 - e. $Y_i = \exp \left\{ -\beta_1 X_{1i} \exp \left[-\beta_2 \left(\frac{1}{X_{2i}} - K \right) \right] \right\} + d_i$.
 - f. $Y_i = X_i (\beta_0 + \beta_1 X_i + \beta_2 X_i^2)^{-1}$.
 - g. $Y_i = \beta_0 X_1^{\beta_1} \exp(-\beta_2 X_i)$.
 - h. $Y_i = \beta_0 \exp(\beta_1 X_i + \beta_2 X_i^2)$.
4. Construya un gráfico apropiado para el modelo $Y_i = \mu + d_i$, teniendo en cuenta los siguientes valores para Y , $Y_1 = 5$, $Y_2 = 3$, $Y_3 = 7$, $Y_4 = 8$, y con las siguientes distancias

$$D_1(\mu) = \sum_{i=1}^4 |Y_i - \mu|.$$

$$D_2(\mu) = \text{Max}\{|Y_i - \mu|\}.$$

$$D_3(\mu) = \sum_{i=1}^4 (Y_i - \mu)^2.$$

¿Cuál distancia recomendaría para el modelo propuesto?

5. En un ensayo experimental agrícola con datos ficticios, suponga que se probaron 5 variedades y 4 fertilizantes. De cada parcela experimental, se seleccionaron aleatoriamente 3 cuadros y se midieron sus rendimientos, lo que arrojó los siguientes resultados:

Fertilizante	Variedades				
	1	2	3	4	5
1	57	26	39	23	45
	46	38	39	36	35
	28	20	43	18	48
2	67	44	57	74	61
	72	68	61	47	60
	66	64	61	69	75
3	95	92	91	98	78
	90	89	82	85	89
	89	99	98	85	95
4	92	96	98	99	99
	88	95	90	98	90
	99	99	98	99	98

- Construya la tabla ANOVA.
 - Con base en el modelo apropiado escriba los cuadrados medios esperados de acuerdo con los siguientes supuestos:
 - Selección aleatoria de variedades y fertilizantes.
 - Variedades y fertilizantes fijos.
 - Una muestra de variedades y fertilizantes fijos.
 - Pruebe la hipótesis de no aditividad en el modelo propuesto.
 - Valide los supuestos sobre los residuales del experimento. ¿Se satisfacen los supuestos del análisis de varianza?
 - ¿A qué conclusiones llega con el análisis de este experimento?
6. Pruebe homogeneidad de varianzas y normalidad para los datos del ejercicio 17 del capítulo 5 a través de las diferentes pruebas presentadas en este capítulo, compare y comente los resultados.

7. Considere los datos y el análisis del ejercicio 10 del capítulo 5.
 - a. Use la prueba de intervalos múltiples N-K para comparar los pares de medias y comente en detalle sus conclusiones.
 - b. Compare los resultados del ítem anterior con los obtenidos al realizar la prueba t -student.
8. Considere los datos y el análisis del ejercicio 18 del capítulo 5. Suponga que se toma como tratamiento control el peso de los niños de las madres no fumadoras.
 - a. Analice los residuos de este experimento ¿Se satisfacen los supuestos del análisis de varianza?
 - b. Use la prueba Dunnet para comparar los pesos de los niños al nacer y comente en detalle sus conclusiones.
 - c. Construya intervalos de confianza para las diferencias de medias y compare los resultados del ítem anterior con los obtenidos al realizar la prueba de Scheffé.
9. La bilirrubina se forma en el hígado cuando la hemoglobina y otra hemoproteína son descompuestas en pigmentos biliosos, esta, a su vez, sufre una fuerte descomposición en el intestino, donde los microorganismos forman la estercobilina café, el principal pigmento de las heces fecales. La bilirrubina es parcialmente reabsorbida por el intestino y retorna nuevamente al hígado si este sufre degeneración. Si la descomposición de hemoglobina es elevada o si la bilis es destruida, la bilirrubina se acumula en altos niveles en la sangre produciendo predisposición. Muestras de sangre fueron tomadas de tres hombres jóvenes en diferentes tiempos durante una semana y la concentración de bilirrubina en la sangre fue medida. Los datos, tomados de Jørgensen (1993), se muestran en la siguiente tabla:

Individuo	Concentración										
1	0.24	0.20	0.23	0.27	0.27	0.34	0.41	0.41	0.55	0.61	0.66
2	0.20	0.27	0.32	0.34	0.34	0.38	0.41	0.41	0.48	0.55	
3	0.32	0.41	0.41	0.55	0.55	0.62	0.71	0.91			

- a. Proponga el modelo para llevar a cabo el análisis de estos datos.
- b. Construya un gráfico de dispersión de los datos.
- c. Lleve a cabo la estimación de los parámetros, construya y grafique los residuales.

- d. Presente el gráfico normal para los residuales.
- e. Haga una transformación logarítmica a los datos y repita b., c. y d.
- f. Lleve a cabo la prueba $H_0 : \tau_1 = \tau_2 = \tau_3 = 0$.
10. A continuación se presenta la salida del análisis de varianza para la variable índice de resistencia del algodón y las comparaciones múltiples de medias de tratamientos de Tukey y Dunnett, como respuesta a 5 diferentes tratamientos; el tratamiento 5 es el testigo y los restantes son tratamientos con fertilizantes. Interprete los resultados que se muestran a continuación y concluya, a la luz del experimento propuesto:

Variable:	Índice				
		Sum of			
Source	DF	Squares	Mean Square	Value	$Pr > F$
rep	2	0.09712000	0.04856000	1.11	0.3750
trat	4	0.73244000	0.18311000	4.19	0.0404
Error	8	0.34948000	0.04368500		
Total	14	1.17904000			

Tukey's Studentized Range (HSD) Test for Índice

Alpha	0.05
Error Degrees of Freedom	8
Error Mean Square	0.043685
Critical Value of Studentized Range	4.88575
Minimum Significant Difference	0.5896

	Tukey Grouping	Mean	N	trat
	A	8.0533	3	2
	A			
B	A	7.8500	3	1
B	A			
B	A	7.7433	3	3
B	A			
B	A	7.5133	3	4
B				
B		7.4500	3	5

Dunnett's t Tests for Indíce

Alpha	0.05
Error Degrees of Freedom	8
Error Mean Square	0.043685
Critical Value of Dunnett's t	3.02271
Minimum Significant Difference	0.5158

Comparisons significant at the 0.05 level are indicated by ***.

Trat	Difference	Simultaneous	
Comparison	Between	95 % Confidence	
	Means	Limits	
2-5	0.6033	0.0875	1.1192 ***
1-5	0.4000	-0.1158	0.9158
3-5	0.2933	-0.2225	0.8092
4-5	0.0633	-0.4525	0.5792

The background features a repeating pattern of mathematical formulas for various mixed-effects models:

- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ijk}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ik}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ij}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{jk}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ik} + e_{ij}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ik} + e_{jk}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ij} + e_{jk}$
- $y_{ijk} = \mu + \tau_i + \beta_j + e_{ik} + e_{ij} + e_{jk}$

Diseño de bloques completamente aleatorizados

7.1. Introducción

El concepto de bloques fue introducido por Fisher hacia 1925 en ensayos en agricultura, observó que los campos experimentales en agricultura marcaban una heterogeneidad de fertilidad, lo que complicaba la asignación de los tratamientos de un punto a otro, de ahí que el bloque permitía la partición de la variabilidad inherente en el campo experimental después de la asignación de los tratamientos en las siguientes componentes:

- i. Diferencias entre tratamientos: variación entre tratamientos.
- ii. Variación dentro de bloques.
- iii. Variación entre bloques.

De esta forma nació el concepto de diseño en bloques completos aleatorizados (DBCA). El término “bloque” es usado más ampliamente para referirse a un grupo de UEs que tienen un conjunto de características que “provocan” un problema efectivo de respuesta, una vez que han sido aplicados los tratamientos.

El DBCA busca básicamente determinar diferencias entre tratamientos, en los que cada uno de estos es aplicado a distintas UEs en cada uno de los bloques; por tal razón, el número de UE por bloques es constante, por ejemplo t .

Por consiguiente, en los DBCA las UE a las que se aplican los tratamientos son subdivididas en grupos homogéneos llamados *bloques*, de tal manera que el número de unidades experimentales dentro de un bloque es igual al número (o a un múltiplo del mismo) de tratamientos en estudio. Una vez caracterizados los bloques, se asignan los tratamientos en forma aleatoria a las UE dentro de cada bloque. Es necesario hacer notar que en este arreglo cada uno de los tratamientos aparece en todos los bloques y cada bloque recibe todos los tratamientos.

En muchos trabajos de tipo experimental, el DBCA es más ventajoso que el DCA, ya que como el objetivo de este DBCA es aislar y eliminar del término de error la variación atribuible a los bloques, con el fin de asegurar que las mediciones hechas sobre las UEs que reciben un determinado tratamiento estén libres de los efectos del bloque. En este sentido, la eficacia del diseño depende de la capacidad de conseguir bloques homogéneos de unidades experimentales. Esta capacidad depende del conocimiento de los investigadores acerca del material experimental. Cuando el diseño se utiliza apropiadamente, el *CME* en la tabla ANOVA se reduce y mejora la probabilidad de rechazar la hipótesis nula.

Una de las ventajas del DBCA es la *flexibilidad* cuando no se hace restricción sobre el número de tratamientos o sobre el número de aplicaciones (número de veces con que una UE recibe un tratamiento) en el experimento. Además, algunas complicaciones que podrían surgir en el transcurso de un experimento son fáciles de controlar cuando se utiliza este diseño.

Tiene como desventaja que no es adecuado cuando se tiene un número grande de tratamientos o cuando los bloques completos presentan una considerable variabilidad.

7.2. Análisis estadístico

A continuación se mostrará la caracterización matemática a través de la formulación de un modelo lineal. Considérese el arreglo del material experimental de la tabla 7.1.

Tabla 7.1: Arreglo de datos para un diseño por bloques completos aleatorizados

Bloques	Tratamientos						Total	Medias
	1	2	...	i	...	t		
1	y_{11}	y_{21}	...	y_{i1}	...	y_{t1}	$y_{.1}$	$\bar{y}_{.1}$
2	y_{12}	y_{22}	...	y_{i2}	...	y_{t2}	$y_{.2}$	$\bar{y}_{.2}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	$\vdots$
j	y_{1j}	y_{2j}	...	y_{ij}	...	y_{tj}	$y_{.j}$	$\bar{y}_{.j}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	$\vdots$
b	y_{1b}	y_{2b}	...	y_{ib}	...	y_{tb}	$y_{.b}$	$\bar{y}_{.b}$
Total	$y_{1.}$	$y_{2.}$	...	$y_{i.}$	...	$y_{t.}$	$y_{..}$	
Medias	$\bar{y}_{1.}$	$\bar{y}_{2.}$	...	$\bar{y}_{i.}$	...	$\bar{y}_{t.}$		$\bar{y}_{..}$

En este caso, y_{ij} hace referencia a la j -ésima replicación asociada al i -ésimo tratamiento. El punto como subíndice indica que se suma sobre el subíndice que está reemplazando, así por ejemplo:

$$y_{i.} = \sum_{j=1}^b y_{ij}, y_{.j} = \sum_{i=1}^t y_{ij}, \bar{y}_{i.} = \frac{1}{b} \sum_{j=1}^b y_{ij}, \bar{y}_{.j} = \frac{1}{t} \sum_{i=1}^t y_{ij}, \bar{y}_{..} = \frac{1}{tb} \sum_{i=1}^t \sum_{j=1}^b y_{ij}.$$

Se presenta a continuación el modelo superparametrizado para identificar el DBCA, dejando el modelo de estructura de medias para el caso de dos factores de clasificación y sin interacción:

$$y_{ijk} = \mu + \tau_i + \beta_j + e_{ijk}, \quad (7.1)$$

donde $i = 1, \dots, t$ es el número de tratamientos, $j = 1, \dots, b$ es el número de bloques y $k = 1, \dots, n_{ij}$ ($n_{ij} \geq 1$) es el número de réplicas.

La contribución de los bloques puede ser considerada como fija o aleatoria. Esta división no puede alterar la inferencia correspondiente a la contribución de los tratamientos. Para efectos de este diseño, el error se asume iid $N(0, \sigma^2)$.

La contribución de tratamientos y bloques es aditiva. Esto implica que la diferencia de dos observaciones en un bloque es:

$$y_{ijk} - y_{i'jk} = (\tau_i - \tau_{i'}) + (\epsilon_{ijk} - \epsilon_{i'jk}).$$

El modelo de bloques no solo especifica la contribución de los tratamientos, sino que si una constante, por ejemplo C , es adicionada a cada tratamiento y restando de μ , se reproduce el modelo (7.1) pero con diferentes parámetros, es decir,

$$\begin{aligned} y_{ijk} &= (\mu - C) + (\tau_i + C) + \beta_j + \epsilon_{ijk} \\ &= \mu^* + \tau_i^* + \beta_j + \epsilon_{ijk} \end{aligned} \quad (7.2)$$

Si en el modelo (7.1), $k = 1$, se obtiene

$$y_{ij} = \mu + \tau_i + \beta_j + e_{ij} \quad (7.3)$$

La estructura matricial para el modelo anterior se reduce a

$$Y = X\beta + \epsilon,$$

donde

$$Y = \begin{pmatrix} y_{11} \\ \vdots \\ y_{1b} \\ \vdots \\ y_{t1} \\ \vdots \\ y_{tb} \end{pmatrix}, \quad \beta = \begin{pmatrix} \mu \\ \tau_1 \\ \vdots \\ \tau_t \\ \beta_1 \\ \vdots \\ \beta_b \end{pmatrix}, \quad \epsilon = \begin{pmatrix} e_{11} \\ \vdots \\ e_{1b} \\ \vdots \\ e_{t1} \\ \vdots \\ e_{tb} \end{pmatrix} \quad y$$

$$X = \begin{bmatrix} \mathbf{1}_n : I_t \otimes \mathbf{1}_b : \mathbf{1}_t \otimes I_b \end{bmatrix}, \quad \text{con } n = tb.$$

El sistema de las ecuaciones normales (EN) es

$$X^t X \beta = X^t Y, \quad (7.4)$$

donde

$$\mathbf{X}^t \mathbf{X} = \begin{bmatrix} tb & b\mathbf{1}_t^t & t\mathbf{1}_b^t \\ b\mathbf{1}_t & b\mathbf{I}_t & \mathbf{J}_{t \times b} \\ t\mathbf{1}_b & \mathbf{J}_{b \times t} & t\mathbf{I}_b \end{bmatrix} \quad \text{y} \quad \mathbf{X}^t \mathbf{Y} = \begin{bmatrix} y_{..} \\ y_{1.} \\ \vdots \\ y_{t.} \\ y_{.1} \\ \vdots \\ y_{.b} \end{bmatrix},$$

con $\mathbf{1}_t$ y $\mathbf{1}_b$ vectores de unos de tamaños $t \times 1$ y $b \times 1$, respectivamente, y $\mathbf{J}_{t \times b}$ y $\mathbf{J}_{b \times t}$ matrices de unos de tamaños $t \times b$ y $b \times t$, respectivamente.

Equivalentemente, las EN descritas en (7.4) se pueden escribir como:

$$\begin{aligned} \text{(i)} \quad & tb\mu + tb\bar{\tau} + tb\bar{\beta} = y_{..} \\ \text{(ii)} \quad & b\mu + b\tau_i + b\bar{\beta} = y_{i.}, \quad i = 1, \dots, t. \\ \text{(iii)} \quad & t\mu + t\bar{\tau} + t\beta_j = y_{.j}, \quad j = 1, \dots, b, \end{aligned} \tag{7.5}$$

donde $\bar{\tau} = \frac{1}{t} \sum_{i=1}^t \tau_i$ y $\bar{\beta} = \frac{1}{b} \sum_{j=1}^b \beta_j$. El interés en este caso es estimar una combinación lineal de tratamientos, por ejemplo, $\lambda = \sum_{i=1}^t a_i \tau_i$.

Siendo

$$\hat{\lambda} = MELI(\lambda) = cy_{..} + l_1 y_{1.} + \dots + l_t y_{t.} + s_1 y_{.1} + \dots + s_b y_{.b}.$$

Tomando esperanza a lado y lado de la expresión anterior, se encuentra:

$$\begin{aligned} E(\hat{\lambda}) &= cE(y_{..}) + E\left(\sum_{i=1}^t l_i y_{i.}\right) + E\left(\sum_{j=1}^b s_j y_{.j}\right) \\ &= ctb(\mu + \bar{\tau} + \bar{\beta}) + b \sum_{i=1}^t l_i (\mu + \tau_i + \bar{\beta}) + t \sum_{j=1}^b s_j (\mu + \bar{\tau} + \beta_j) \\ &= \mu \left(tbc + b \sum_{i=1}^t l_i + t \sum_{j=1}^b s_j \right) + \sum_{i=1}^t \tau_i \left(bc + bl_i + \sum_{j=1}^b s_j \right) \\ &\quad + \sum_{j=1}^b \beta_j \left(tc + \sum_{i=1}^t l_i + ts_j \right). \end{aligned}$$

Si se desea que el estimador sea insesgado, se iguala la anterior ecuación a λ , lo cual conlleva a satisfacer que:

$$\begin{aligned} \text{(a)} \quad & tbc + b \sum_{i=1}^t l_i + t \sum_{j=1}^b s_j = 0. \\ \text{(b)} \quad & bc + bl_i + \sum_{j=1}^b s_j = a_i, \quad i = 1, \dots, t. \\ \text{(c)} \quad & tc + \sum_{i=1}^t l_i + ts_j = 0, \quad j = 1, \dots, b. \end{aligned} \tag{7.6}$$

Al sumar sobre i en la ecuación (7.6)(b) y reemplazar en (7.6)(a), se tiene que $\sum_{i=1}^t a_i \tau_i$ es estimable si $\sum_{i=1}^t a_i = 0$.

Para obtener el MELI, del sistema de ecuaciones normales en (7.5), de (ii) y de (i) se deduce que:

$$\hat{\tau}_i - \bar{\tau} = \frac{y_{i.}}{b} - \frac{y_{..}}{tb}$$

y su valor esperado es

$$E\left(\frac{y_{i.}}{b} - \frac{y_{..}}{tb}\right) = \tau_i - \bar{\tau}.$$

Observe que $\frac{y_{i.}}{b} - \frac{y_{..}}{tb}$ se puede escribir de la forma

$$\mathbf{q}^t \mathbf{X}^t \mathbf{Y} = \left(-\frac{1}{tb}, \frac{1}{b}, \dots, \frac{1}{b}, 0, \dots, 0\right) \mathbf{Y}.$$

Por tanto, teniendo en cuenta algunos resultados del capítulo 3, se satisface que:

$$MELI(\tau_i - \bar{\tau}) = \frac{y_{i.}}{b} - \frac{y_{..}}{tb},$$

obteniendo así un contraste lineal $\lambda = \sum_{i=1}^t a_i \tau_i = \sum_{i=1}^t a_i (\tau_i - \bar{\tau})$ y su MELI, está dado por:

$$\begin{aligned} MELI(\lambda) &= \sum_{i=1}^t a_i MELI(\tau_i - \bar{\tau}) \\ &= \sum_{i=1}^t a_i \left(\frac{y_{i.}}{b} - \frac{y_{..}}{tb}\right) = \sum_{i=1}^t a_i \frac{y_{i.}}{b}. \end{aligned}$$

Finalmente, el estimador del contraste es $\hat{\lambda} = \sum_{i=1}^t a_i \bar{y}_{i.}$

En términos generales algunos contrastes de interés son:

- i) $\tau_i - \tau_{i'}, \quad i \neq i', \quad i, i' = 1, 2, \dots, t$
- ii) $\tau_i - \bar{\tau}, \quad i = 1, \dots, t.$

La varianza de $\hat{\lambda}$ es $V(\hat{\lambda}) = \frac{\sigma^2}{b} \sum_{i=1}^t a_i^2$ y sobre normalidad $\hat{\lambda} \sim N(\lambda, V(\hat{\lambda}))$.

Una forma equivalente de escribir $\hat{\lambda}$ es:

$$\hat{\lambda} = b^{-1} \sum_{j=1}^b \left(\sum_{i=1}^t a_i y_{ij} \right),$$

donde la cantidad en el paréntesis es un contraste de la respuesta dentro del j -ésimo bloque y es invariante por la adición de una constante común para cada observación en el bloque. La hipótesis de interés tiene en cuenta la igualdad de efectos de tratamientos, es decir,

$$H_0 : \tau_i = 0, \quad \forall i,$$

la cual tiene como estadístico de prueba

$$F = \frac{CM(Trat)}{CME}$$

El CME es un estimador insesgado de σ^2 y puede ser usado para construir intervalos de confianza (IC) para λ . En la construcción del intervalo se parte de la variabilidad pivote

$$\frac{\hat{\lambda} - \lambda}{\sqrt{\frac{CME}{b} \sum_{i=1}^t a_i^2}} \sim t_{((b-1)(t-1))}.$$

En el modelo (7.1) $k \neq 1$, se busca el sistema de EN a partir de minimizar la suma de cuadrados del error presentada a continuación:

$$Q(\mu, \tau_1, \dots, \tau_t, \beta_1, \dots, \beta_b) = \sum_{i=1}^t \sum_{j=1}^b \sum_{k=1}^{n_{ij}} e_{ijk}^2,$$

derivando parcialmente con respecto a cada uno de los parámetros se obtiene:

$$\begin{aligned} \frac{\partial Q}{\partial \mu} &= 2 \sum_{i=1}^t \sum_{j=1}^b \sum_{k=1}^{n_{ij}} (y_{ijk} - \mu - \tau_i - \beta_j)(-1) = 0 \\ \frac{\partial Q}{\partial \tau_i} &= 2 \sum_{j=1}^b \sum_{k=1}^{n_{ij}} (y_{ijk} - \mu - \tau_i - \beta_j)(-1) = 0, \quad i = 1, \dots, t \\ \frac{\partial Q}{\partial \beta_j} &= 2 \sum_{i=1}^t \sum_{k=1}^{n_{ij}} (y_{ijk} - \mu - \tau_i - \beta_j)(-1) = 0, \quad j = 1, \dots, b. \end{aligned} \quad (7.7)$$

Al resolver el sistema anterior, se obtienen las ecuaciones normales

$$\begin{aligned} n_{..}\hat{\mu} + \sum_{i=1}^t n_{i.}\hat{\tau}_i + \sum_{j=1}^b n_{.j}\hat{\beta}_j &= y_{...} \\ n_{i.}\hat{\mu} + n_{i.}\hat{\tau}_i + \sum_{j=1}^b n_{ij}\hat{\beta}_j &= y_{i..}, \quad i = 1, \dots, t \\ n_{.j}\hat{\mu} + \sum_{i=1}^t n_{ij}\hat{\tau}_i + n_{.j}\hat{\beta}_j &= y_{.j.}, \quad j = 1, \dots, b, \end{aligned} \quad (7.8)$$

donde $n_{..} = \sum_{i=1}^t \sum_{j=1}^b n_{ij}$, $n_{i.} = \sum_{j=1}^b n_{ij}$, $n_{.j} = \sum_{i=1}^t n_{ij}$, $y_{...} = \sum_{i=1}^t \sum_{j=1}^b \sum_{k=1}^{n_{ij}} y_{ijk}$, $y_{i..} = \sum_{j=1}^b \sum_{k=1}^{n_{ij}} y_{ijk}$ y $y_{.j.} = \sum_{i=1}^t \sum_{k=1}^{n_{ij}} y_{ijk}$.

Al imponer las condiciones de no estimabilidad,

$$\sum_{i=1}^t n_{i.}\tau_i = 0 \quad \text{y} \quad \sum_{j=1}^b n_{.j}\beta_j = 0$$

se obtienen los siguientes estimadores para los parámetros μ , α_i y β_j , respectivamente,

$$\hat{\mu} = \frac{y_{...}}{n_{..}} = \bar{y}_{...}, \quad \hat{\alpha}_i = \frac{y_{i..}}{n_{i.}} - \hat{\mu} = \bar{y}_{i..} - \bar{y}_{...}, \quad i = 1, \dots, t$$

y

$$\hat{\beta}_j = \frac{y_{.j.}}{n_{.j}} - \hat{\mu} = \bar{y}_{.j.} - \bar{y}_{...}, \quad j = 1, \dots, b.$$

El análisis de varianza se origina de la partición de la suma de cuadrados corregida por la media en tres sumas de cuadrados independientes: la primera, debida a la variabilidad entre los bloques; la segunda debida a la variabilidad entre los tratamientos ajustada por bloques, y la tercera, debida a la variación dentro tratamientos y bloques.

Para calcular las respectivas sumas de cuadrados, se hace uso del procedimiento conocido como *mínimos cuadrados reducidos* (ver capítulo 2 sobre modelos lineales), con este procedimiento se obtiene:

$$SCTrat = R(\tau/\mu, \beta) = \sum_{i=1}^t \hat{\tau}_i \left(y_{i..} - \sum_{j=1}^b \frac{n_{ij}y_{.j.}}{n_{.j}} \right),$$

lo cual representa la suma de cuadrados debida a los efectos de tratamientos eliminando bloques.

La variación atribuible al modelo completo o suma de cuadrados del modelo completo es:

$$SC(\mu, \tau, \beta) = R(\mu, \tau, \beta) = \hat{\mu}y_{...} + \sum_{j=1}^b \hat{\beta}_j y_{.j.} + \sum_{i=1}^t \hat{\tau}_i y_{i..} \quad (7.9)$$

La expresión (7.9) se puede escribir de la forma

$$\begin{aligned} SC(\mu, \tau, \beta) &= \sum_{j=1}^b \frac{y_{.j.}^2}{n_{.j}} + \sum_{i=1}^t \left(y_{i..} - \sum_{j=1}^b \frac{n_{ij} y_{.j.}}{n_{.j}} \right) \hat{\tau}_i \\ &= \frac{y_{...}^2}{n_{..}} + \left(\sum_{j=1}^b \frac{y_{.j.}^2}{n_{.j}} - \frac{y_{...}^2}{n_{..}} \right) + \sum_{i=1}^t \hat{\tau}_i \left(y_{i..} - \sum_{j=1}^b \frac{n_{ij} y_{.j.}}{n_{.j}} \right) \end{aligned} \quad (7.10)$$

o, equivalentemente,

$$R(\tau, \beta / \mu) = R(\beta / \mu) + R(\tau / \mu, \beta),$$

donde $R(\tau, \beta / \mu) = SC(\mu, \tau, \beta) - \frac{y_{...}^2}{n_{..}}$, $R(\beta / \mu) = \sum_{j=1}^b \frac{y_{.j.}^2}{n_{.j}} - \frac{y_{...}^2}{n_{..}}$ y $R(\tau / \mu, \beta) = \sum_{i=1}^t \hat{\tau}_i \left(y_{i..} - \sum_{j=1}^b \frac{n_{ij} y_{.j.}}{n_{.j}} \right)$.

Del sistema (7.10), se debe tener en cuenta que $R(\beta / \mu)$ representa la suma de cuadrados de bloques ignorando el efecto de tratamientos.

La suma de cuadrados total y del errores, respectivamente:

$$\begin{aligned} SCT_{CM} &= \sum_{ijk} y_{ijk}^2 - \frac{y_{...}^2}{n_{..}} \\ SCE &= \sum_{ijk} y_{ijk}^2 - SC(\mu, \tau, \beta). \end{aligned}$$

Los anteriores resultados se resumen en la tabla 7.2 de ANOVA.

Tabla 7.2: Análisis de varianza de un DBCA con $k \neq 1$

C de V	gl	SC	CM
Bloq. ignorando trat.	$b - 1$	$R(\beta / \mu)$	
Trat. ajustado bloq.	$t - 1$	$R(\tau / \mu, \beta)$	$\frac{R(\tau / \mu, \beta)}{\frac{SCE}{n_{..} - b - t + 1}}$
Error	$n_{..} - b - t + 1$	SCE	
Total	$n_{..} - 1$	SCT_{CM}	

La hipótesis de igualdad de tratamientos, $H_0 : \tau_1 = \dots = \tau_t$, se prueba a través del estadístico

$$F = \frac{CM(\text{Trat. ajustado bloq.})}{CME} \sim F_{(t-1, n_{..}-b-t+1)},$$

donde $CM(\text{Trat. ajustado bloq.}) = \frac{R(\tau/\mu, \beta)}{t-1}$ y $CME = \frac{SCE}{n_{..}-b-t+1}$. Por consiguiente, se rechaza H_0 si $F_c > F_{(t-1, n_{..}-b-t+1, \alpha)}$ a un nivel de significación α .

Si $n_{ij} = r$ en el modelo (7.1), entonces la suma de cuadrados total corregida puede expresarse como:

$$\sum_{ijk} (y_{ijk} - \bar{y}_{...})^2 = \sum_{ijk} [(\bar{y}_{i..} - \bar{y}_{...}) + (\bar{y}_{.j.} - \bar{y}_{...}) + (y_{ijk} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...})]^2.$$

Mediante procedimientos algebraicos simples, se prueba que los tres productos cruzados son cero. Por lo tanto,

$$\begin{aligned} \sum_{ijk} (y_{ijk} - \bar{y}_{...})^2 &= br \sum_{i=1}^t (\bar{y}_{i..} - \bar{y}_{...})^2 + tr \sum_{j=1}^b (\bar{y}_{.j.} - \bar{y}_{...})^2 \\ &\quad + \sum_{ijk} (y_{ijk} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...})^2, \end{aligned} \quad (7.11)$$

representa una partición de la suma de cuadrados total corregida. Al expresar simbólicamente las sumas de cuadrados de (7.11), se tiene

$$SCT_{CM} = SCT_{rat} + SCB_{loq} + SCE.$$

Puesto que hay tbr observaciones, SCT_{CM} tiene $tbr - 1$ grados de libertad. Hay t tratamientos y b bloques, de donde SCT_{rat} y SCB_{loq} tienen, al igual que antes, $t - 1$ y $b - 1$ grados de libertad, respectivamente. La SCE tiene como grados de libertad la diferencia entre los del total y tratamientos junto con bloques.

El valor esperado de los cuadrados medios, cuando los tratamientos y los bloques son fijos, es:

$$\begin{aligned} E(CM_{Trat}) &= \sigma^2 + \frac{br \sum_{i=1}^t \tau_i^2}{t-1}, & E(CM_{Bloq}) &= \sigma^2 + \frac{tr \sum_{j=1}^b \beta_j^2}{b-1} \quad \text{y} \\ E(CME) &= \sigma^2. \end{aligned}$$

Por lo tanto, para llevar a cabo la prueba de igualdad de efectos entre tratamientos, se usa el estadístico

$$F = \frac{CM_{Trat}}{CME} \sim F_{(t-1, tbr-t-r+1)}.$$

Se rechaza H_0 si $F_0 > F_{(t-1, tbr-t-r+1, \alpha)}$. En este caso, también podría haber interés en comparar las medias de los bloques porque “quizá” no sea necesaria la formación de bloques en experimentos futuros. Según los cuadrados

medios esperados, aparentemente la hipótesis $H_0 : \beta_1 = \dots = \beta_b$ puede probarse comparando el estadístico $F_B = CMBloq/CME$ con $F_{(b-1, tbr-t-r+1, \alpha)}$. Sin embargo, recordando que la aleatorización solo se ha aplicado a los tratamientos *dentro* de los bloques, es decir, los bloques representan una *restricción sobre la aleatorización* Box, Hunter y Hunter (1978) señalan que la prueba F del análisis de varianza común puede justificarse exclusivamente con la aleatorización y sin el uso directo del supuesto de normalidad. Agregan que en la prueba para comparar bloques no puede recurrirse a dicha justificación debido a la restricción sobre la aleatorización, pero si los errores son normales e idénticamente distribuidos con media cero y varianza constante σ^2 , puede usarse el estadístico F_B para comparar las medias de los bloques.

Ejemplo 7.1. *Un agrónomo desea determinar el efecto de diferentes fuentes de nitrógeno en la producción de una materia seca sobre cebada forrajera. Hay cinco fuentes a ser comparadas: $(NH_4)_2SO_4$, NH_4NO_3 , $NaNO_3$, $CO(NH_2)_2$, $Ca(NO_3)_2$ y un tratamiento control sin nitrógeno. Se desean aplicar los resultados sobre un rango bastante amplio de condiciones; se hicieron ensayos sobre cuatro tipos de suelo (Martínez 1981).*

Para el diseño experimental se eligió un diseño en bloques completamente aleatorizado con los tipos de suelo como factor de bloqueo, se localizaron seis parcelas en cada uno de los cuatro tipos de suelo, y se asignó aleatoriamente los tratamientos a las parcelas dentro de cada tipo de suelo. La variable de interés es la producción (kg/parcela) de cebada bajo varias fuentes de nitrógeno.

Los datos obtenidos al realizar este experimento se presentan en la tabla 7.3.

Tabla 7.3: Producción (en kg/parcela) de cebada bajo varias fuentes de nitrógeno

Tratamiento	Tipo de suelo			
	I	II	III	IV
$(NH_4)_2SO_4$	32.1	35.6	41.9	35.4
NH_4NO_3	30.1	31.5	37.1	30.8
$CO(NH_2)_2$	25.4	27.1	33.8	31.1
$Ca(NO_3)_2$	24.1	33.0	35.6	31.4
$NaNO_3$	26.1	31.0	33.8	31.9
Control	23.2	24.8	26.7	26.7

Las sumas de cuadrados son las siguientes:

$$SCT_{CM} = \sum_{ij} y_{ij}^2 - \frac{y_{..}^2}{n_{..}} = 23323.52 - \frac{740.2^2}{24} = 494.52$$

$$\begin{aligned}
SCTrat &= \sum_{i=1}^t \hat{\tau}_i \left(y_{i.} - \sum_{j=1}^b \frac{n_{ij} y_{.j}}{n_{.j}} \right) = \frac{1}{b} \sum_{i=1}^6 y_{i.}^2 - \frac{y_{..}^2}{n_{..}} \\
&= \frac{1}{4} [145^2 + 129.5^2 + 117.4^2 + 124.1^2 + 122.8^2 + 101.4^2] \\
&\quad - \frac{740.2^2}{24} = 256.15 \\
SCBloq &= R(\beta / \mu) = \sum_{j=1}^b \frac{y_{.j}^2}{n_{.j}} - \frac{y_{..}^2}{n_{..}} = \frac{1}{t} \sum_{j=1}^4 y_{.j}^2 - \frac{y_{..}^2}{n_{..}} \\
&= \frac{1}{6} [161^2 + 183^2 + 208.9^2 + 187.3^2] - \frac{740.2^2}{24} = 192.75 \\
SCE &= SCT_{CM} - SCTrat - SCBloq \\
&= 494.52 - 256.15 - 192.75 = 45.62.
\end{aligned}$$

Con base en los anteriores resultados, se construye la tabla 7.4. A partir de la cual, con un nivel de significación del 5%, el valor $F_{(5,15,0.05)} = 2.90$ y $F_c = 16.85$ mayor que el tabulado, se concluye que el tipo de nitrógeno afecta la producción de cebada. Además, al parecer, los tipos de suelo (bloques) difieren de manera significativa, ya que el cuadrado medio es grande en relación con el cuadrado medio del error.

Tabla 7.4: Análisis de varianza para la producción de cebada según varias fuentes de nitrógeno

C de V	gl	SC	CM	F	Valor p
Suelo	3	192.75	64.25	21.13	0.00
Tratamiento	5	256.15	51.23	16.85	0.00
Error	15	45.62	3.04		
Total	23	494.52			

7.3. Estimación de una observación faltante

Las observaciones faltantes surgen por muchas razones: un animal puede morir, una parcela puede ser inundada, se puede enfermar un trabajador, etc. Un efecto inmediato que trae para el análisis es la falta de simetría de la información, ya que cualquier observación faltante daña el balanceo de los datos. Podría abordarse el análisis como un caso de bloques incompletos. Sin embargo, existen procedimientos útiles para estimar las parcelas faltantes. A continuación se ilustra el caso en el que se tiene una observación faltante y la forma de obtener una estimación de esta.

Considere el esquema de bloques de la tabla 7.5, donde $Y_{i.}^*$, $Y_{.j}^*$ y $Y_{..}^*$ son las sumas de las observaciones en el tratamiento i -ésimo, bloque j -ésimo y total, respectivamente, sin la inclusión del dato x .

Tabla 7.5: Tabla de datos para DBCA con un dato faltante

Bloques	Tratamientos						Total
	1	2	...	i	...	t	
1	y_{11}	y_{21}	...	y_{i1}	...	y_{t1}	$y_{.1}$
2	y_{12}	y_{22}	...	y_{i2}	...	y_{t2}	$y_{.2}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
j	y_{1j}	y_{2j}	...	x	...	y_{tj}	$y_{.j}^* + x$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
b	y_{1b}	y_{2b}	...	y_{ib}	...	y_{tb}	$y_{.b}$
Total	$y_{1.}$	$y_{2.}$	...	$y_{i.}^* + x$	...	$y_{t.}$	$y_{..}^* + x$

Supóngase que se perdió la ij -ésima observación (llámese x), entonces, al considerar la suma de cuadrados del error,

$$\begin{aligned}
 SCE &= SCT_{CM} - SCT_{rat} - SCB_{loq} \\
 &= \sum_{q=1}^t \sum_{\substack{p=1 \\ q \neq i}}^b y_{qp}^2 + x^2 - \frac{(y_{..}^* + x)^2}{tb} - \frac{1}{b} \sum_{\substack{q=1 \\ q \neq i}}^t y_{q.}^2 - \frac{1}{b} (y_{i.}^* + x)^2 \\
 &\quad + \frac{(y_{..}^* + x)^2}{tb} - \frac{1}{t} \sum_{\substack{p=1 \\ p \neq j}}^b y_{.p}^2 - \frac{1}{t} (y_{.j}^* + x)^2 + \frac{(y_{..}^* + x)^2}{tb} \\
 &= \sum_{q=1}^t \sum_{\substack{p=1 \\ q \neq i}}^b y_{qp}^2 + x^2 - \frac{1}{b} \sum_{\substack{q=1 \\ q \neq i}}^t y_{q.}^2 - \frac{1}{b} (y_{i.}^* + x)^2 + \frac{(y_{..}^* + x)^2}{tb} \\
 &\quad - \frac{1}{t} \sum_{\substack{p=1 \\ p \neq j}}^b y_{.p}^2 - \frac{1}{t} (y_{.j}^* + x)^2,
 \end{aligned}$$

minimizándola con respecto a x ,

$$\frac{\partial SCE}{\partial x} = 2x - \frac{2}{b} (y_{i.}^* + x) + \frac{2}{tb} (y_{..}^* + x) - \frac{2}{t} (y_{.j}^* + x);$$

igualando a cero,

$$x \left(1 - \frac{1}{b} + \frac{1}{tb} - \frac{1}{t} \right) = \frac{y_{i.}^*}{b} + \frac{y_{.j}^*}{t} - \frac{y_{..}^*}{tb}.$$

Finalmente, se tiene como estimador de la parcela faltante a la expresión

$$\hat{x} = \frac{ty_{i.}^* + by_{.j}^* - y_{..}^*}{(t-1)(b-1)}. \quad (7.12)$$

Si más de dos valores se pierden, procediendo de forma similar se obtienen las expresiones para la estimación:

$$\begin{aligned} \hat{x}_{ij} &= \frac{by_{.j}^* + ty_{i.}^* - y_{..}^{**} - \hat{x}_{i'j'}}{(t-1)(b-1)} \\ \hat{x}_{i'j'} &= \frac{by_{.j'}^* + ty_{i'.}^* - y_{..}^{**} - \hat{x}_{ij}}{(t-1)(b-1)}. \end{aligned}$$

Realizando los procedimientos algebraicos apropiados en las dos expresiones anteriores, se encuentran las estimaciones de los dos datos faltantes, dadas por:

$$\begin{aligned} \hat{x}_{ij} = \frac{1}{(t-1)^2(b-1)^2 - 1} \{ &t(t-1)(b-1)y_{i.}^* + b(b-1)(t-1)y_{.j}^* \\ &- ty_{i'.}^* - by_{.j'}^* - [(t-1)(b-1) - 1]y_{..}^{**} \} \end{aligned}$$

y

$$\begin{aligned} \hat{x}_{i'j'} = \frac{1}{(t-1)^2(b-1)^2 - 1} \{ &t(t-1)(b-1)y_{i'.}^* + b(b-1)(t-1)y_{.j'}^* \\ &- ty_{i.}^* - by_{.j}^* - [(t-1)(b-1) - 1]y_{..}^{**} \}, \end{aligned}$$

donde $y_{i.}^*$, $y_{i'.}^*$, $y_{.j}^*$, $y_{.j'}^*$ y $y_{..}^{**}$ son las sumas sobre el tratamiento i e i' , bloques j y j' y total, respectivamente, sin incluir los datos x_{ij} y $x_{i'j'}$ que representan la información faltante.

De manera alternativa, puede utilizarse la ecuación (7.12) de forma iterativa para estimar los valores faltantes.

Observación 7.1.

- Por cada observación que se estime se pierde un grado de libertad en el error, en general, se debe cumplir que $glE = (b-1)(t-1)$ - número de observaciones estimadas.
- Bajo la hipótesis nula, el valor esperado de $CM(Trat)$ es mayor que el valor esperado del cuadrado medio del error (CME). De esta forma, cualquier hipótesis que no sea correcta conllevará a una prueba sesgada y solo es considerada como una prueba aproximada. La corrección de estos sesgos consiste en disminuir la $SC(Trat)$ en la cantidad

$\frac{[y_{.j}^* - (t-1)\hat{x}]^2}{t(t-1)} = S$, con lo cual se obtiene una nueva suma de cuadrados de tratamientos, $SCTrat_{Corr} = SCTrat - S$.

Obteniendo, así, en el caso de una observación faltante, la tabla 7.6 de ANOVA.

Tabla 7.6: Análisis de varianza corregido cuando se estima una observación faltante

C de V	gl	SC
Media	1	$SC(\mu)$
Bloques	$b - 1$	$SC(Bloq)$
Tratamientos	$t - 1$	$SC(Trat)_{Corr}$
Error	$(b - 1)(t - 1) - 1$	SCE
Total	$bt - 1$	$\sum_{ij} y_{ij}^2 - S$

7.4. Eficiencia de un DBCA frente a un DCA

En muchas circunstancias, el investigador desea estimar la eficiencia del uso de un DBCA contra un DCA, aun si todos los tratamientos hubiesen sido completamente aleatorizados en todas las UE. Un método para comparar eficiencia consiste en comparar algebraicamente lo que podría haber pasado al CME_{DBCA} bajo aleatorización completa.

Recordando que

$$CME_{DBCA} = \frac{SCE_{DBCA}}{(t - 1)(b - 1)}$$

y teniendo en cuenta que el cuadrado medio del error de un DCA en términos de un DBCA está dado por:

$$CME_{DCA} = \frac{(b - 1)CMBloq + (t - 1)(b - 1)CME_{DBCA}}{t(b - 1)},$$

la eficiencia relativa (ER) del DCA con respecto al DBCA es:

$$\begin{aligned} ER &= \frac{CME_{DCA}}{CME_{DBCA}} = \frac{CMBloq + (t - 1)CME_{DBCA}}{tCME_{DBCA}} \\ &= \frac{1}{t} \frac{CMBloq}{CME_{DBCA}} + \left(1 - \frac{1}{t}\right) \\ &= 1 + \frac{1}{t} \left(\frac{CMBloq}{CME_{DBCA}} - 1 \right). \end{aligned}$$

Si $CMBloq > CME_{DBCA}$, entonces $ER > 1$, y es mejor usar un DBCA. Si $CMBloq \leq CME_{DBCA}$, entonces $ER \leq 1$, y es mejor usar un DCA.

Ejemplo 7.2. Con base en los datos obtenidos en el ejemplo 7.1, al suponer que se perdió el dato correspondiente al tratamiento NH_4NO_3 del tipo de suelo III y realizar su estimación se encuentra, al utilizar la ecuación (7.12), que

$$x = \frac{ty_{i.}^* + by_{.j}^* - y_{..}^*}{(t-1)(b-1)} = \frac{6(92.4) + 4(171.8) - 703.1}{(5)(3)} = 35.9.$$

La anterior estimación del dato faltante no difiere mucho del dato observado, 37.1, aceptando este procedimiento de estimación como apropiado.

La eficiencia del DBCA con respecto al DCA para saber si realmente el DBCA está reduciendo el ruido en los datos para que las diferencias entre los seis tratamientos sean detectadas. Así, la ER del DCA con respecto al DBCA es:

$$\begin{aligned} ER &= 1 + \frac{1}{t} \left(\frac{CMBloques}{CME_{DBCA}} - 1 \right) \\ &= 1 + \frac{1}{6} \left(\frac{64.25}{3.04} - 1 \right) = 4.35, \end{aligned}$$

con el anterior resultado se comprueba la efectividad de haber considerado el tipo de suelo como un factor de control local en este experimento.

7.5. Bloques con submuestreo

En muchas situaciones experimentales, se hace necesario tomar muestras dentro de las unidades experimentales, de tal modo que cada respuesta se obtenga a partir de muestras tamaño s dentro de cada parcela (UE), logrando un total de tbs observaciones. Tal es el caso de tomar, por ejemplo, granos dentro de mazorcas, hojas dentro de plantas, alumnos dentro de cursos, etc. Estos ensayos se pueden estructurar según la tabla 7.7.

El modelo asociado con este arreglo del material experimental es:

$$y_{ijk} = \mu + \tau_i + \beta_j + \epsilon_{ij} + \eta_{ijk}, \quad (7.13)$$

con $i = 1, 2, \dots, t$, $j = 1, 2, \dots, b$ y $k = 1, 2, \dots, s$, en donde ϵ_{ij} es el error experimental, el cual se supone tiene $E(\epsilon_{ij}) = 0$ y $E(\epsilon_{ij}^2) = \sigma^2$, η_{ijk} es el error de muestreo, el cual tiene $E(\eta_{ijk}) = 0$ y $E(\eta_{ijk}^2) = \sigma^2$.

Además, hay independencia entre estos dos tipos de errores, la misma se manifiesta en el hecho de que $E(\epsilon_{ij}\eta_{ijk}) = 0$, para todo ijk .

Tabla 7.7: Estructura de datos en un diseño en bloques con submuestreo

Tratamientos	Bloques			
	1	2	...	b
1	y_{111}	y_{121}	...	y_{1b1}
	y_{112}	y_{122}	...	y_{1b2}
	$\vdots$	$\vdots$	$\ddots$	$\vdots$
	y_{11s}	y_{12s}	...	y_{1bs}
	Total 1	$y_{11.}$	$y_{12.}$	...
2	y_{211}	y_{221}	...	y_{2b1}
	y_{212}	y_{222}	...	y_{2b2}
	$\vdots$	$\vdots$	$\ddots$	$\vdots$
	y_{21s}	y_{22s}	...	y_{2bs}
	Total 2	$y_{21.}$	$y_{22.}$	...
t	$\vdots$	$\vdots$	$\ddots$	$\vdots$
	y_{t11}	y_{t21}	...	y_{tb1}
	y_{t12}	y_{t22}	...	y_{tb2}
	$\vdots$	$\vdots$	$\ddots$	$\vdots$
	y_{t1s}	y_{t2s}	...	y_{tbs}
Total t	$t_{1.}$	$y_{t2.}$	...	$y_{tb.}$

7.5.1. Formas de obtener las sumas de cuadrados

Suponiendo el modelo (7.13), las diferentes sumas de cuadrados necesarias para la construcción de la tabla ANOVA son obtenidas a partir de las siguientes expresiones:

$$\begin{aligned}
 SCBloq &= \sum_{j=1}^b \frac{y_{.j.}^2}{ts} - \frac{y_{...}^2}{tbs} \\
 SCTrat &= \sum_{i=1}^t \frac{y_{i..}^2}{bs} - \frac{y_{...}^2}{tbs} \\
 SCEM &= \sum_{ijk} y_{ijk}^2 - \sum_{ij} \frac{y_{ij.}^2}{s} \\
 SCEE &= \sum_{ij} \frac{y_{ij.}^2}{s} - \sum_{i=1}^t \frac{y_{i..}^2}{bs} - \sum_{j=1}^b \frac{y_{.j.}^2}{ts} + \frac{y_{...}^2}{tbs}
 \end{aligned}$$

$$SCT_{CM} = \sum_{ijk} y_{ijk}^2 - \frac{y_{...}^2}{tbs}.$$

La tabla ANOVA se resume en la tabla 7.8.

Tabla 7.8: Análisis de varianza del diseño en bloques con submuestreo

C de V	gl	SC	CM	F
Bloques	$b - 1$	$SCBloq$	$CMBloq = \frac{SCBloque}{b-1}$	
Trat.	$t - 1$	$SCTrat$	$CMTrat = \frac{SCTrat}{t-1}$	$CMTrat/CMEE$
EE	$(b - 1)(t - 1)$	$SCEE$	$CMEE = \frac{SCEE}{(t-1)(b-1)}$	
EM	$tb(s - 1)$	$SCEM$	$CMEM = \frac{SCEM}{tb(s-1)}$	
Total	$tbs - 1$	SCT_{CM}		

Para juzgar la hipótesis de igualdad de tratamientos ($H_0 : \tau_1 = \cdots = \tau_t$), se hace uso del estadístico de prueba

$$F_t = \frac{CMTrat}{CMEE} \sim F_{(t-1, (t-1)(b-1))}.$$

Entonces, se rechaza H_0 si $F_t > F_{(t-1, (t-1)(b-1), \alpha)}$.

Si se desea probar la hipótesis

$$H_0 : \sigma_\epsilon^2 = 0 \quad \text{contra} \quad H_a : \sigma_\epsilon^2 > 0,$$

se tiene como estadístico de prueba

$$F_v = \frac{CMEE}{CMEM} \sim F_{((t-1)(b-1), tb(s-1))},$$

rechazando la hipótesis nula si $F_v > F_{((t-1)(b-1), tb(s-1), \alpha)}$.

Ejemplo 7.3. Un agricultor roció hojas de manzana con diferentes concentraciones de un compuesto de nitrógeno, luego determinó la cantidad de nitrógeno (mg/dm^2) que permanecía en las hojas inmediatamente después de la aplicación y al final de ciertos tiempos preestablecidos. La finalidad de este experimento fue determinar la rapidez con la que el nitrógeno es absorbido por las hojas. Se realizaron dos reproducciones de cada tratamiento, tal como se muestra en la tabla 7.9.

Tabla 7.9: Cantidad de nitrógeno a través del tiempo que permanece después de su aplicación

Tiempos	Concentración de nitrógeno		
	n_1	n_2	n_3
t_0	2.29	6.80	8.75
	2.54	5.94	9.52
t_1	0.46	3.03	2.49
	0.19	1.00	2.04
t_2	0.00	0.75	1.40
	0.26	1.16	1.81

Las sumas de cuadrados asociadas a los diferentes efectos son:

$$SC_{Bloq} = \sum_{j=1}^3 \frac{y_{.j}^2}{ts} - \frac{y_{...}^2}{tbs} = \frac{1}{6} [35.84^2 + 9.21^2 + 5.38^2] - \frac{50.43^2}{18}$$

$$= 91.76$$

$$SCT_{rat} = \sum_{i=1}^3 \frac{y_{i..}^2}{bs} - \frac{y_{...}^2}{tbs} = \frac{1}{6} [5.74^2 + 18.68^2 + 26.01^2] - \frac{50.43^2}{18}$$

$$= 35.11$$

$$SC_{EM} = \sum_{ijk} y_{ijk}^2 - \sum_{ij} \frac{y_{ij.}^2}{s}$$

$$= 288.41 - \frac{1}{2} [4.83^2 + 12.74^2 + \dots + 3.21^2] = 3.10$$

$$SC_{EE} = \sum_{ij} \frac{y_{ij.}^2}{s} - \sum_{i=1}^t \frac{y_{i..}^2}{bs} - \sum_{j=1}^b \frac{y_{.j.}^2}{ts} + \frac{y_{...}^2}{tbs}$$

$$= 285.32 - 176.40 - 233.05 + 141.29 = 17.16$$

$$SCT_{CM} = \sum_{ijk} y_{ijk}^2 - \frac{y_{...}^2}{tbs} = 288.41 - 141.29 = 147.12.$$

Asumiendo un bloqueo por tiempos, al llevar a cabo el análisis de varianza y teniendo como hipótesis de interés $H_0 : \mu_{n_1} = \mu_{n_2} = \mu_{n_3}$, se obtiene el ANOVA que se muestra en la tabla 7.10.

De los resultados de la tabla 7.10, se concluye que la permanencia de nitrógeno en las hojas no se ve afectada por la cantidad de nitrógeno aplicada, puesto que $F_{(2,4,0.05)} = 6.94 > F_c = 4.09$. Por otro lado, al parecer los tiempos (bloques) difieren de manera significativa, ya que el cuadrado medio es grande en relación con el error experimental.

Ahora, si se desea probar la hipótesis $H_0 : \sigma_{EE}^2 = 0$, se observa en la tabla 7.10 que $F_c = 12.46 > F_{(4,9,0.05)} = 3.63$, luego se tiene evidencia para rechazar H_0 . Con base en este resultado se concluye que el submuestreo es importante en este experimento.

Tabla 7.10: Análisis de varianza para la cantidad de nitrógeno (mg/dm^2) que permanece en las hojas

C de V	gl	SC	CM	F	Valor p
Tiempo	2	91.76	45.88		
Nitrógeno	2	35.11	17.56	4.09	0.11
EE	4	17.16	4.29	12.46	0.00
EM	9	3.10	0.34		
Total	17	147.12			

Finalmente, al utilizar los resultados obtenidos en el capítulo 4, se tienen dos componentes de varianza para estimar (σ_{EE}^2 y σ_{EM}^2). La estimación de dichas componentes se obtiene a partir de los cuadrados medios, estas son

$$\hat{\sigma}_{EM}^2 = CMEM = 0.34$$

y

$$\hat{\sigma}_{EM}^2 + 2\hat{\sigma}_{EE}^2 = CMEE.$$

Luego,

$$\hat{\sigma}_{EE}^2 = \frac{CMEE - CMEM}{2} = \frac{4.29 - 0.34}{2} = 1.97.$$

Normalmente estas estimaciones no dan una información fácilmente interpretable. Sin embargo, según estos resultados, se encuentra que hay mayor variabilidad entre unidades experimentales en los diferentes bloques, que entre unidades observacionales dentro de la misma unidad experimental. Este resultado confirma la importancia del submuestreo en el bloqueo.

Dentro de los ensayos en bloques, es frecuente que se tenga una serie de experimentos en bloques asignados en diferentes localidades. Considérese, por ejemplo, el arreglo de la tabla 7.11.

Con base en las observaciones de la tabla 7.11, se tiene entonces el modelo:

$$y_{isj} = \mu + \tau_i + \gamma_s + (\tau\gamma)_{is} + \beta_{j(s)} + \epsilon_{isj},$$

donde τ_i es el efecto del tratamiento i -ésimo ($i = 1, \dots, t$), β_j es el efecto de bloque j -ésimo ($j = 1, \dots, b$) y γ_s es el efecto de localidad s -ésima ($s = 1, \dots, k$).

Tabla 7.11: Diseño en bloques en diferentes localidades

Localidad	Bloque	Tratamiento				
		1	2	...	t	y _{sj}
1	1	y ₁₁₁	y ₂₁₁	...	y _{t11}	y _{·11}
	2	y ₁₁₂	y ₂₁₂	...	y _{t12}	y _{·12}
	⋮	⋮	⋮	⋮	⋮	⋮
	b	y _{11b}	y _{21b}	...	y _{t1b}	y _{·1b}
	y _{i1.}	y _{11.}	y _{21.}	...	y _{t1.}	y _{·1.}
⋮	⋮	⋮	⋮		⋮	⋮
k	1	y _{1k1}	y _{2k1}	...	y _{tk1}	y _{·k1}
	2	y _{1k2}	y _{2k2}	...	y _{tk2}	y _{·k2}
	⋮	⋮	⋮	⋮	⋮	⋮
	b	y _{1kb}	y _{2kb}	...	y _{tkb}	y _{·kb}
	y _{ik.}	y _{1k.}	y _{2k.}	...	y _{tk.}	y _{·k.}
y _{i..}	⋮	y _{1..}	y _{2..}	...	y _{t..}	y _{...}

Caracterizado el modelo se obtiene el sistema de ecuaciones normales:

$$\begin{aligned}
 y_{...} &= tbk\mu + bk \sum_i \tau_i + tb \sum_s \gamma_s + b \sum_{is} \tau\gamma_{is} + t \sum_{sj} \beta_{j(s)} \\
 y_{i..} &= bk\mu + bk\tau_i + b \sum_s \gamma_s + b \sum_s \tau\gamma_{is} + \sum_{sj} \beta_{j(s)} \\
 y_{.s.} &= tb\mu + b \sum_i \tau_i + tb\gamma_s + b \sum_i \tau\gamma_{is} + t \sum_j \beta_{j(s)} \\
 y_{is.} &= b\mu + b\tau_i + b\gamma_s + b\tau\gamma_{is} + \sum_j \beta_{j(s)} \\
 y_{.sj} &= t\mu + \sum_i \tau_i + t\gamma_s + \sum_i \tau\gamma_{is} + t \sum_j \beta_{j(s)}.
 \end{aligned}$$

Una solución al sistema se obtiene al imponer las restricciones:

$$\sum_i \tau_i = \sum_s \gamma_s = \sum_i \tau\gamma_{is} = \sum_s \tau\gamma_{is} = \sum_j \beta_{j(s)} = \sum_{sj} \beta_{j(s)} = 0.$$

Así, el conjunto de soluciones son:

$$\hat{\mu} = \frac{y_{...}}{tbk} = \bar{y}_{...}, \quad \hat{\tau}_i = \frac{y_{i..}}{bk} - \hat{\mu} = \bar{y}_{i..} - \bar{y}_{...}, \quad \hat{\gamma}_s = \frac{y_{.s.}}{tb} - \hat{\mu} = \bar{y}_{.s.} - \bar{y}_{...}$$

$$\widehat{\tau\gamma_{is}} = \frac{y_{is.}}{b} - \hat{\mu} - \hat{\tau}_i - \hat{\gamma}_s = \bar{y}_{is.} - \bar{y}_{i..} - \bar{y}_{.s.} + \bar{y}_{...} \quad \text{y} \quad \hat{\beta}_{j(s)} = \frac{y_{.sj}}{t} - \hat{\mu} - \hat{\gamma}_s = \bar{y}_{.sj} - \bar{y}_{.s.}$$

Las respectivas sumas de cuadrados son:

$$\begin{aligned}
 SC(\mu) &= \frac{y_{...}^2}{tbk} = C \\
 SC(T) &= \sum_i \hat{\tau}_i y_{i..} = \sum_i \left(\frac{y_{i..}}{bk} - \hat{\mu} \right) y_{i..} \\
 &= \frac{1}{bk} \sum_i y_{i..}^2 - C \\
 SC(L) &= \sum_s \hat{\gamma}_s y_{.s.} = \sum_s \left(\frac{y_{.s.}}{tb} - \hat{\mu} \right) y_{.s.} \\
 &= \frac{1}{tb} \sum_s y_{.s.}^2 - C \\
 SC(TL) &= \sum_{is} \hat{\tau} \hat{\gamma}_{is} y_{is.} = \sum_{is} \left(\frac{y_{is.}}{b} - \hat{\mu} - \hat{\tau}_i - \hat{\gamma}_s \right) y_{is.} \\
 &= \sum_{is} \frac{y_{is.}^2}{b} - \hat{\mu} y_{...} - \sum_i \hat{\tau}_i y_{i..} - \sum_s \hat{\gamma}_s y_{.s.} \\
 &= \sum_{is} \frac{y_{is.}^2}{b} - C - SC(T) - SC(L) \\
 SC(B(L)) &= \sum_{sj} \hat{\beta}_{j(s)} y_{.sj} = \sum_{sj} \left(\frac{y_{.sj}}{t} - \hat{\mu} - \hat{\gamma}_s \right) y_{.sj} \\
 &= \sum_{sj} \frac{y_{.sj}^2}{t} - \hat{\mu} y_{...} - \sum_s \hat{\gamma}_s y_{.s.} \\
 &= \sum_{sj} \frac{y_{.sj}^2}{t} - C - SC(L) \\
 &= \sum_s \left[\frac{\sum_j y_{.sj}^2}{t} - \frac{y_{.s.}^2}{tb} \right] = \sum_s (SC(B))_s.
 \end{aligned}$$

Finalmente, la suma de cuadrados del error esta dada por:

$$\begin{aligned}
 SCE &= SCT_{CM} - SC(T) - SC(L) - SC(TL) - SC(B(L)) \\
 &= \sum_s \left[\sum_{ij} y_{isj}^2 - \frac{1}{b} \sum_i y_{is.}^2 - \frac{1}{t} \sum_j y_{.sj}^2 + \frac{1}{tb} y_{.s.}^2 \right] \\
 &= \sum_s \left[\sum_{ij} y_{isj}^2 - \frac{y_{.s.}^2}{tb} - \left(\frac{1}{b} \sum_i y_{is.}^2 - \frac{y_{.s.}^2}{tb} \right) - \frac{1}{t} \sum_j y_{.sj}^2 + \frac{y_{.s.}^2}{tb} \right]
 \end{aligned}$$

$$SCE = \sum_s [SCT_{CM} - SC(T) - SC(B)]_s.$$

Adicionalmente, se construyen los cuadrados medios esperados para este experimento, los cuales se encuentran en la tabla 7.12.

Tabla 7.12: Cuadrados medios esperados para un diseño en bloque en diferentes localidades

C de V	gl	E(CM)
Tratamientos	$t - 1$	$\sigma^2 + b\sigma_{TL}^2 + \frac{bk}{t-1} \sum_i \tau_i^2$
Localidad	$k - 1$	$\sigma^2 + t\sigma_b^2 + \frac{tb}{k-1} \sum_s \gamma_s^2$
Error(trats $\times$ local)	$(t - 1)(k - 1)$	$\sigma^2 + b\sigma_{TL}^2$
Bloq:local	$k(b - 1)$	$\sigma^2 + t\sigma_b^2$
Error	$k(t - 1)(b - 1)$	σ^2
Total	$tkb - 1$	

Los componentes de varianza se pueden estimar como:

$$\hat{\sigma}^2 = CME, \quad \hat{\sigma}_b^2 = \frac{CM(Bloq : Local) - CME}{t} \quad y$$

$$\hat{\sigma}_{TL}^2 = \frac{CM(T \times L) - CME}{b}$$

Al evaluar la diferencia de medias entre dos tratamientos se tiene la varianza de la estimación del contraste entre dos medias como:

$$\begin{aligned} V(\hat{\mu}_i - \hat{\mu}_{i'}) &= \frac{2k}{k^2} \sigma_{TL}^2 + \frac{2bk}{b^2 k^2} \sigma^2 = \frac{2}{k} \sigma_{TL}^2 + \frac{2}{bk} \sigma^2 \\ &= \frac{2}{bk} (b\sigma_{TL}^2 + \sigma^2) = \frac{2}{bk} CM(T \times L) \end{aligned}$$

Por consiguiente, para contrastar $H_0 : \mu_i = \mu_{i'}$ se plantea como estadístico de prueba

$$t = \frac{\hat{\mu}_i - \hat{\mu}_{i'}}{\sqrt{\frac{2}{bk} (b\hat{\sigma}_{TL}^2 + \hat{\sigma}^2)}} = \frac{y_{i..} - y_{i'..}}{\sqrt{\frac{2}{bk} CM(T \times L)}},$$

con el cual se rechaza H_0 si $|t| > t_{(2, (t-1)(k-1), 0.05)}$.

7.6. Diseño en bloques incompletos

En un agrupamiento simple, como es el diseño en bloques aleatorizados, el material experimental se divide en grupos, cada grupo es una repetición.

Con ello se busca mantener el error experimental dentro de cada grupo tan pequeño como sea posible.

El diseño en bloques aleatorizados tiene entre sus ventajas resultados “más exactos” que los diseños completamente aleatorios, además, el análisis estadístico es sencillo, ya que por ser un diseño ortogonal posee óptimas propiedades.

Pese a estas ventajas, en ocasiones cuando se ensaya un gran número de tratamientos, no es posible llevar a cabo una asignación de todos y cada uno de los bloques, con lo cual se rompe una de las condiciones experimentales de los bloques completos, ya que el material experimental puede ser bastante heterogéneo. En este caso, se divide el material experimental en bloques de tamaños adecuados para el experimento; a este diseño o arreglo del material experimental se le conoce como Diseño en Bloques Incompletos (DBI). En investigación agropecuaria, por ejemplo, es frecuente el uso de bloques incompletos equilibrados, los reticulares cuadrados, latices en dos dimensiones y los bloques con tratamientos comunes.

7.6.1. Estructuras matriciales de los bloques incompletos

En la conducción de un experimento de bloques incompletos, se considera inicialmente un arreglo en b bloques con t tratamientos, en el cual el i -ésimo tratamiento ($i = 1, 2, \dots, t$) aparece en r_i bloques, el j -ésimo bloque ($j = 1, 2, \dots, b$) tiene k_j unidades experimentales por bloque, de las cuales n_{ij} reciben el tratamiento i -ésimo.

En esta dirección, inicialmente se introducen tres matrices a partir de las cuales se construyen los demás arreglos, así:

- i. $\mathbf{R}_{t \times t}$ es una matriz diagonal, en el que el i -ésimo elemento de la diagonal es r_i , $i = 1, \dots, t$. Por consiguiente,

$$\mathbf{R} = \begin{pmatrix} r_1 & 0 & \cdots & 0 \\ 0 & r_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & r_t \end{pmatrix} \text{ y el vector de repeticiones } \mathbf{r} = \begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_t \end{pmatrix}.$$

- ii. $\mathbf{K}_{b \times b}$ es una matriz diagonal, en la cual el j -ésimo elemento de la diagonal es k_j , $j = 1, 2, \dots, b$. Luego,

$$K = \begin{pmatrix} k_1 & 0 & \cdots & 0 \\ 0 & k_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & k_b \end{pmatrix}, \text{ y el vector de elementos } \mathbf{k} = \begin{pmatrix} k_1 \\ k_2 \\ \vdots \\ k_b \end{pmatrix}.$$

- iii. $N = [n_{ij}]_{t \times b}$ es la matriz de incidencia con elementos n_{ij} ($i = 1, \dots, t$, $j = 1, \dots, b$), los elementos de esta matriz están constituidos por el número de veces que el tratamiento i aparece en el bloque j , esta matriz caracteriza completamente el diseño. Explícitamente, la matriz de incidencia se escribe como:

$$N = \begin{pmatrix} n_{11} & n_{12} & \cdots & n_{1b} \\ n_{21} & n_{22} & \cdots & n_{2b} \\ \vdots & \vdots & \ddots & \vdots \\ n_{t1} & n_{t2} & \cdots & n_{tb} \end{pmatrix}.$$

Adicionalmente, en cada estructura del diseño, se debe construir la matriz $N^t N$ cuadrada de orden t , denominada matriz de concordancia, en la cual el elemento en la fila i y la columna h , n_{ih} , están conformados por el número de bloques en el cual aparecen el i -ésimo y h -ésimo tratamientos juntos. Explícitamente, esta matriz es de la forma:

$$N^t N = \begin{pmatrix} \sum_{i=1}^t n_{i1}^2 & \sum_{i=1}^t n_{i1}n_{i2} & \cdots & \sum_{i=1}^t n_{i1}n_{ij} & \cdots & \sum_{i=1}^t n_{i1}n_{ib} \\ \sum_{i=1}^t n_{i2}n_{i1} & \sum_{i=1}^t n_{i2}^2 & \cdots & \sum_{i=1}^t n_{i2}n_{ij} & \cdots & \sum_{i=1}^t n_{i2}n_{ib} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \sum_{i=1}^t n_{ih}n_{i1} & \sum_{i=1}^t n_{ih}n_{i2} & \cdots & \sum_{i=1}^t n_{ih}n_{ij} & \cdots & \sum_{i=1}^t n_{ih}n_{ib} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \sum_{i=1}^t n_{ib}n_{i1} & \sum_{i=1}^t n_{ib}n_{i2} & \cdots & \sum_{i=1}^t n_{ib}n_{ij} & \cdots & \sum_{i=1}^t n_{ib}^2 \end{pmatrix}.$$

En su forma más general, el modelo estadístico asociado a cualquier estructura de Bloques Completos o Incompletos está dado en (7.1).

El proceso de estimación en este diseño se hace vía mínimos cuadrados, para ello se minimiza la suma de cuadrados del error intrabloque, es decir, se minimiza

$$\sum_{i=1}^t \sum_{j=1}^b \sum_{k=1}^{n_{ij}} \epsilon_{ijk}^2 = \sum_{i=1}^t \sum_{j=1}^b \sum_{k=1}^{n_{ij}} [y_{ijk} - (\mu + \tau_i + \beta_j)]^2.$$

Obteniendo el siguiente conjunto de ecuaciones normales, una vez se deriva respecto a (μ, τ_i, β_j) y se iguala a cero,

- i. $G = n_{..}\mu + \sum_{i=1}^t r_i \tau_i + \sum_{j=1}^b k_j \beta_j.$
- ii. $T_i = r_i \mu + r_i \tau_i + \sum_{j=1}^b n_{ij} \beta_j, i = 1, \dots, t.$
- iii. $B_j = k_j \mu + \sum_{i=1}^t n_{ij} \tau_i + k_j \beta_j, j = 1, \dots, b.$

Matricialmente el conjunto de ecuaciones normales es representado explícitamente por el siguiente sistema:

$$\begin{pmatrix} G \\ T_1 \\ \vdots \\ T_t \\ B_1 \\ \vdots \\ B_b \end{pmatrix} = \begin{pmatrix} n_{..} & r_1 & \cdots & r_t & k_1 & \cdots & k_b \\ r_1 & r_1 & \cdots & 0 & n_{11} & \cdots & n_{1b} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ r_t & 0 & \cdots & r_t & n_{t1} & \cdots & n_{tb} \\ k_1 & n_{11} & \cdots & n_{t1} & k_1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ k_b & n_{1b} & \cdots & n_{tb} & 0 & \cdots & k_b \end{pmatrix} \begin{pmatrix} \mu \\ \tau_1 \\ \vdots \\ \tau_t \\ \beta_1 \\ \vdots \\ \beta_b \end{pmatrix}$$

o, equivalentemente,

$$\begin{aligned} G &= n_{..}\mu + \mathbf{1}^t \mathbf{R} \boldsymbol{\tau} + \mathbf{1}^t \mathbf{K} \boldsymbol{\beta} \\ \mathbf{T} &= \mathbf{R} \mathbf{1} \mu + \mathbf{R} \boldsymbol{\tau} + \mathbf{N} \boldsymbol{\beta} \\ \mathbf{B} &= \mathbf{K} \mathbf{1} \mu + \mathbf{N}^t \boldsymbol{\tau} + \mathbf{K} \boldsymbol{\beta}. \end{aligned} \quad (7.14)$$

Para solucionar el sistema de ecuaciones, se premultiplica (7.14) por la matriz

$$\begin{pmatrix} 1 & 0 & 0 \\ 0 & \mathbf{I}_t & -\mathbf{N} \mathbf{K}^{-1} \\ 0 & -\mathbf{N}^t \mathbf{R}^{-1} & \mathbf{I}_b \end{pmatrix},$$

donde $\mathbf{I}_t, \mathbf{I}_b$ son matrices idénticas de tamaño $t \times t$ y $b \times b$, respectivamente, $\mathbf{N}, \mathbf{R}$ y $\mathbf{K}$ son las matrices definidas anteriormente; más detalles en John (1971) y González (1997).

De esta premultiplicación, se obtiene el siguiente sistema de ecuaciones:

$$\begin{pmatrix} 1 & 0 & 0 \\ 0 & \mathbf{I}_t & -\mathbf{N} \mathbf{K}^{-1} \\ 0 & -\mathbf{N}^t \mathbf{R}^{-1} & \mathbf{I}_b \end{pmatrix} \begin{pmatrix} G \\ \mathbf{T} \\ \mathbf{B} \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \mathbf{I}_t & -\mathbf{N} \mathbf{K}^{-1} \\ 0 & -\mathbf{N}^t \mathbf{R}^{-1} & \mathbf{I}_b \end{pmatrix} \begin{pmatrix} n_{..} & \mathbf{1}^t \mathbf{R} & \mathbf{1}^t \mathbf{K} \\ \mathbf{R} \mathbf{1} & \mathbf{R} & \mathbf{N} \\ \mathbf{K} \mathbf{1} & \mathbf{N}^t & \mathbf{K} \end{pmatrix} \begin{pmatrix} \mu \\ \boldsymbol{\tau} \\ \boldsymbol{\beta} \end{pmatrix}$$

$$\begin{pmatrix} G \\ T - \mathbf{N}\mathbf{K}^{-1}\mathbf{B} \\ \mathbf{B} - \mathbf{N}^t\mathbf{R}^{-1}\mathbf{T} \end{pmatrix} = \begin{pmatrix} n & \mathbf{1}^t\mathbf{R} & \mathbf{1}^t\mathbf{K} \\ \mathbf{R}\mathbf{1} - \mathbf{N}\mathbf{K}^{-1}\mathbf{K}\mathbf{1} & \mathbf{R} - \mathbf{N}\mathbf{K}^{-1}\mathbf{N}^t & \mathbf{N} - \mathbf{N}\mathbf{K}^{-1}\mathbf{K} \\ \mathbf{K}\mathbf{1} - \mathbf{N}^t\mathbf{R}^{-1}\mathbf{R}\mathbf{1} & \mathbf{N}^t - \mathbf{N}^t\mathbf{R}^{-1}\mathbf{R} & \mathbf{K} - \mathbf{N}^t\mathbf{R}^{-1}\mathbf{N} \end{pmatrix} \begin{pmatrix} \mu \\ \tau \\ \beta \end{pmatrix}.$$

Del conjunto de ecuaciones anterior, se sigue $\mathbf{R}\mathbf{1} = \mathbf{N}\mathbf{1} = \mathbf{r}$ y $\mathbf{K}\mathbf{1} = \mathbf{N}^t\mathbf{1} = \mathbf{k}$. Con estas consideraciones, se encuentra finalmente el sistema de ecuaciones normales:

$$\begin{aligned} \text{a) } G &= n\mu + \mathbf{1}^t\mathbf{R}\tau + \mathbf{1}^t\mathbf{K}\beta \\ \text{b) } T - \mathbf{N}\mathbf{K}^{-1}\mathbf{B} &= (\mathbf{R} - \mathbf{N}\mathbf{K}^{-1}\mathbf{N}^t)\tau \\ \text{c) } \mathbf{B} - \mathbf{N}^t\mathbf{R}^{-1}\mathbf{T} &= (\mathbf{K} - \mathbf{N}^t\mathbf{R}^{-1}\mathbf{N})\beta. \end{aligned} \quad (7.15)$$

De este sistema, al hacer $\mathbf{Q} = T - \mathbf{N}\mathbf{K}^{-1}\mathbf{B}$ y $\mathbf{C} = \mathbf{R} - \mathbf{N}\mathbf{K}^{-1}\mathbf{N}^t$, se expresa la ecuación (7.15)b) como

$$\mathbf{Q} = \mathbf{C}\tau, \quad (7.16)$$

donde $\mathbf{Q}$ es el vector de totales de tratamiento ajustados, es decir,

$$\begin{aligned} \mathbf{Q} &= \begin{pmatrix} T_1 \\ T_2 \\ \vdots \\ T_t \end{pmatrix} - \begin{pmatrix} n_{11} & n_{12} & \cdots & n_{1b} \\ n_{21} & n_{22} & \cdots & n_{2b} \\ \vdots & \vdots & \ddots & \vdots \\ n_{t1} & n_{t2} & \cdots & n_{tb} \end{pmatrix} \begin{pmatrix} \frac{1}{k_1} & 0 & \cdots & 0 \\ 0 & \frac{1}{k_2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \frac{1}{k_b} \end{pmatrix} \begin{pmatrix} B_1 \\ B_2 \\ \vdots \\ B_b \end{pmatrix} \\ \mathbf{Q} &= \begin{pmatrix} Q_1 \\ Q_2 \\ \vdots \\ Q_t \end{pmatrix} = \begin{pmatrix} T_1 - \sum_{j=1}^b \frac{n_{1j}B_j}{k_j} \\ T_2 - \sum_{j=1}^b \frac{n_{2j}B_j}{k_j} \\ \vdots \\ T_t - \sum_{j=1}^b \frac{n_{tj}B_j}{k_j} \end{pmatrix} = \begin{pmatrix} y_{1..} - \sum_{j=1}^b \frac{n_{1j}y_{.j.}}{k_j} \\ y_{2..} - \sum_{j=1}^b \frac{n_{2j}y_{.j.}}{k_j} \\ \vdots \\ y_{t..} - \sum_{j=1}^b \frac{n_{tj}y_{.j.}}{k_j} \end{pmatrix}, \end{aligned}$$

donde $Q_i = T_i - \sum_{j=1}^b \frac{n_{ij}B_j}{k_j}$ el total del tratamiento i ajustado por los bloques.

Además, si $\mathbf{C}$ es la matriz intrabloque no singular dada por:

$$\mathbf{C} = \begin{pmatrix} r_1 - \sum_{j=1}^b \frac{n_{1j}^2}{k_j} & -\sum_{j=1}^b \frac{n_{1j}n_{2j}}{k_j} & \cdots & -\sum_{j=1}^b \frac{n_{1j}n_{tj}}{k_j} \\ -\sum_{j=1}^b \frac{n_{1j}n_{2j}}{k_j} & r_2 - \sum_{j=1}^b \frac{n_{2j}^2}{k_j} & \cdots & -\sum_{j=1}^b \frac{n_{2j}n_{tj}}{k_j} \\ \vdots & \vdots & \ddots & \vdots \\ -\sum_{j=1}^b \frac{n_{1j}n_{tj}}{k_j} & -\sum_{j=1}^b \frac{n_{2j}n_{tj}}{k_j} & \cdots & r_t - \sum_{j=1}^b \frac{n_{tj}^2}{k_j} \end{pmatrix},$$

A la ecuación (7.16) se le conoce como sistema de ecuaciones normales eliminando el efecto de bloques o ecuaciones normales ajustadas por bloques. Para encontrar la solución al sistema (7.16) y por la singularidad de C , se satisface que $Q^t \mathbf{1} = (T - NK^{-1}B)^t \mathbf{1} = \sum_{i=1}^t T_i - B^t K^{-1} \mathbf{k} = \sum_{i=1}^t T_i - \sum_{j=1}^b B_j = 0$, luego es un sistema consistente.

De esta forma, la solución al sistema admite que C sea invertible. Cuando esto no sucede la literatura recomienda usar la inversa de Moore Penrose (John 1971) o hacer los siguientes ajustes en la matriz C para hacerla invertible:

$$(C + aJ)^{-1}, \text{ con } a = \frac{\lambda}{k} \text{ si es balanceado,}$$

donde λ es el número de veces que cada par de tratamientos aparece en el mismo bloque, $k = k_1 = \dots = k_b$ y $\Omega = C + \frac{r r^t}{n_{..}}$, en forma explícita, se expresa como:

$$\Omega = \begin{pmatrix} r_1 - \sum_{j=1}^b \frac{n_{1j}^2}{k_j} & - \sum_{j=1}^b \frac{n_{1j}n_{2j}}{k_j} & \dots & - \sum_{j=1}^b \frac{n_{1j}n_{tj}}{k_j} \\ - \sum_{j=1}^b \frac{n_{1j}n_{2j}}{k_j} & r_2 - \sum_{j=1}^b \frac{n_{2j}^2}{k_j} & \dots & - \sum_{j=1}^b \frac{n_{2j}n_{tj}}{k_j} \\ \vdots & \vdots & \ddots & \vdots \\ - \sum_{j=1}^b \frac{n_{1j}n_{tj}}{k_j} & - \sum_{j=1}^b \frac{n_{2j}n_{tj}}{k_j} & \dots & r_t - \sum_{j=1}^b \frac{n_{tj}^2}{k_j} \end{pmatrix} + \frac{1}{n} \begin{pmatrix} r_1^2 & r_1 r_2 & \dots & r_1 r_t \\ r_1 r_2 & r_2^2 & \dots & r_2 r_t \\ \vdots & \vdots & \ddots & \vdots \\ r_1 r_t & r_t r_2 & \dots & r_t^2 \end{pmatrix}$$

$$= \begin{pmatrix} r_1 - \sum_{j=1}^b \frac{n_{1j}^2}{k_j} + \frac{r_1^2}{n} & \frac{r_1 r_2}{n} - \sum_{j=1}^b \frac{n_{1j}n_{2j}}{k_j} & \dots & \frac{r_1 r_t}{n} - \sum_{j=1}^b \frac{n_{1j}n_{tj}}{k_j} \\ \frac{r_1 r_2}{n} - \sum_{j=1}^b \frac{n_{1j}n_{2j}}{k_j} & r_2 - \sum_{j=1}^b \frac{n_{2j}^2}{k_j} + \frac{r_2^2}{n} & \dots & \frac{r_2 r_t}{n} - \sum_{j=1}^b \frac{n_{2j}n_{tj}}{k_j} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{r_1 r_t}{n} - \sum_{j=1}^b \frac{n_{1j}n_{tj}}{k_j} & \frac{r_2 r_t}{n} - \sum_{j=1}^b \frac{n_{2j}n_{tj}}{k_j} & \dots & r_t - \sum_{j=1}^b \frac{n_{tj}^2}{k_j} + \frac{r_t^2}{n} \end{pmatrix}.$$

Esta última expresión de Ω es útil para cuando hay desigual número de réplicas dentro de cada bloque incompleto.

Ejemplo 7.4. En el siguiente ejemplo, tomado de John (1971), se probaron tres tratamientos, A , B y C , en un diseño incompleto de cinco bloques. Los resultados del experimento se presentan en la siguiente tabla:

Bloque	Tratamiento				Total
B_1	$A = 12$	$A = 12$	$B = 14$	$C = 16$	54
B_2	$B = 16$	$C = 18$			34
B_3	$A = 16$	$A = 16$	$B = 18$	$C = 20$	70
B_4	$A = 18$	$B = 20$			38
B_5	$A = 20$	$C = 24$			44

Con base en los datos obtenidos: $t = 3$, $b = 5$, $T_1 = 94$, $T_2 = 68$, $T_3 = 78$, $G = 240$,

$$\mathbf{R} = \begin{pmatrix} 6 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{pmatrix}, \mathbf{K} = \begin{pmatrix} 4 & 0 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 \\ 0 & 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 0 & 2 \end{pmatrix} \text{ y } \mathbf{N} = \begin{pmatrix} 2 & 0 & 2 & 1 & 1 \\ 1 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 0 & 1 \end{pmatrix}.$$

Para obtener las estimaciones de τ_i y β_j , se encuentra:

$$\mathbf{C} = \mathbf{R} - \mathbf{N}\mathbf{K}^{-1}\mathbf{N}^t = \begin{pmatrix} 6 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{pmatrix} - \begin{pmatrix} 3 & \frac{3}{2} & \frac{3}{2} \\ \frac{3}{2} & \frac{3}{2} & 1 \\ \frac{3}{2} & 1 & \frac{3}{2} \end{pmatrix} = \frac{1}{2} \begin{pmatrix} 6 & -3 & -3 \\ -3 & 5 & -2 \\ -3 & -2 & 5 \end{pmatrix}$$

$$\mathbf{Q} = \mathbf{T} - \mathbf{N}\mathbf{K}^{-1}\mathbf{B} = \begin{pmatrix} 94 \\ 68 \\ 78 \end{pmatrix} - \begin{pmatrix} \frac{2}{4} & 0 & \frac{2}{4} & \frac{1}{2} & \frac{1}{2} \\ \frac{1}{4} & \frac{1}{2} & \frac{1}{4} & \frac{1}{2} & 0 \\ \frac{1}{4} & \frac{1}{2} & \frac{1}{4} & 0 & \frac{1}{2} \end{pmatrix} \begin{pmatrix} 54 \\ 34 \\ 70 \\ 38 \\ 44 \end{pmatrix} = \begin{pmatrix} -9 \\ 1 \\ 8 \end{pmatrix}.$$

Al considerar una inversa generalizada simétrica de la forma

$$\mathbf{\Omega} = \mathbf{C} + a\mathbf{J}, \quad \text{entonces} \quad \mathbf{\Omega}^{-1} = (\mathbf{C} + a\mathbf{J})^{-1},$$

donde a es un número escalar diferente de cero que depende del tipo de diseño (Hinkelmann y Kempthorne 2005). De este modo,

$$\mathbf{\Omega} = \mathbf{C} + \frac{3}{2}\mathbf{J} = \frac{1}{2} \begin{pmatrix} 9 & 0 & 0 \\ 0 & 8 & 1 \\ 0 & 1 & 8 \end{pmatrix} \quad \text{y} \quad \mathbf{\Omega}^{-1} = \frac{2}{63} \begin{pmatrix} 7 & 0 & 0 \\ 0 & 8 & -1 \\ 0 & -1 & 8 \end{pmatrix}.$$

Una solución para $\boldsymbol{\tau}$ en (7.16) es:

$$\hat{\boldsymbol{\tau}} = \mathbf{\Omega}^{-1}\mathbf{Q} = \begin{pmatrix} -2 \\ 0 \\ 2 \end{pmatrix}.$$

Al imponer la condición $\mathbf{1}^t\boldsymbol{\beta} = 0$ en la ecuación (7.14), en la cual $\mathbf{B} = \mathbf{K}\mathbf{1}\mu + \mathbf{N}^t\boldsymbol{\tau} + \mathbf{K}\boldsymbol{\beta}$, se tiene, al premultiplicar por $\mathbf{1}^t\mathbf{K}^{-1}$, que

$$\mathbf{1}^t\mathbf{K}^{-1}\mathbf{B} = \mathbf{1}^t\mathbf{1}\mu + \mathbf{1}^t\mathbf{K}^{-1}\mathbf{N}^t\boldsymbol{\tau}$$

Siguiendo con los datos del ejemplo, $\mathbf{1}^t\mathbf{K}^{-1}\mathbf{B} = 89$, $\mathbf{1}^t\mathbf{K}^{-1}\mathbf{N}^t\hat{\boldsymbol{\tau}} = -1$ y $\mathbf{1}^t\mathbf{1}\hat{\mu} = 5\hat{\mu}$. Luego, $89 = 5\hat{\mu} - 1$ y, por consiguiente, $\hat{\mu} = 18$.

De la ecuación $\mathbf{B} = \mathbf{K}\mathbf{1}\hat{\mu} + \mathbf{K}\boldsymbol{\beta} + \mathbf{N}^t\hat{\tau}$, se sigue que:

$$\hat{\boldsymbol{\beta}} = \mathbf{K}^{-1}(\mathbf{B} - \mathbf{K}\mathbf{1}\hat{\mu} - \mathbf{N}^t\hat{\tau}) = \begin{pmatrix} -4 \\ -2 \\ 0 \\ 2 \\ 4 \end{pmatrix}.$$

Otra inversa generalizada que difiere de $\boldsymbol{\Omega}$, la cual debe asociarse cuando los tratamientos no se replican el mismo número de veces, es denotado por $\boldsymbol{\Omega}^*$. En este caso, $\boldsymbol{\Omega}^* = \mathbf{C} + \mathbf{r}\mathbf{r}^t/n_{..}$. Con los datos del ejemplo, se tiene:

$$\mathbf{r}\mathbf{r}^t = \begin{pmatrix} 6 \\ 4 \\ 4 \end{pmatrix} \begin{pmatrix} 6 & 4 & 4 \end{pmatrix} = \begin{pmatrix} 36 & 24 & 24 \\ 24 & 16 & 16 \\ 24 & 16 & 16 \end{pmatrix}.$$

Como $n_{..} = 14$, entonces

$$\boldsymbol{\Omega}^* = \frac{1}{14} \begin{pmatrix} 78 & 3 & 3 \\ 3 & 51 & 2 \\ 3 & 2 & 51 \end{pmatrix} \quad y \quad \boldsymbol{\Omega}^{*-1} = \frac{1}{294} \begin{pmatrix} 53 & -3 & -3 \\ -3 & 81 & -3 \\ -3 & -3 & 81 \end{pmatrix}$$

$$\tilde{\boldsymbol{\tau}} = \boldsymbol{\Omega}^{*-1}\mathbf{Q} = \frac{1}{7} \begin{pmatrix} -12 \\ 2 \\ 16 \end{pmatrix} = \begin{pmatrix} -1.7142 \\ 0.2857 \\ 2.2857 \end{pmatrix}.$$

Imponiendo la condición $\mathbf{1}^t\mathbf{K}\boldsymbol{\beta} = 0$ y siguiendo la metodología aplicada a $\boldsymbol{\Omega}$ en el procedimiento anterior, se sigue que:

$$\tilde{\mu} = \frac{120}{7}, \quad \tilde{\boldsymbol{\beta}} = \frac{1}{7} \begin{pmatrix} -24 \\ -10 \\ 4 \\ 18 \\ 32 \end{pmatrix}.$$

Se observa que $\hat{\boldsymbol{\tau}} \neq \tilde{\boldsymbol{\tau}}$, sin embargo, $\hat{\tau}_1 - \hat{\tau}_2 = -2 = \tilde{\tau}_1 - \tilde{\tau}_2$ y, simultáneamente, $\hat{\tau}_3 - \hat{\tau}_1 = \tilde{\tau}_3 - \tilde{\tau}_1 = 4$. La relación entre $\hat{\boldsymbol{\tau}}$ y $\tilde{\boldsymbol{\tau}}$ es $\tilde{\boldsymbol{\tau}} = \hat{\boldsymbol{\tau}} + \frac{2}{7}\mathbf{1}$ y, para algún vector $\mathbf{c}$ tal que $\mathbf{c}^t\mathbf{1} = 0$, se satisface que $\mathbf{c}^t\hat{\boldsymbol{\tau}} = \mathbf{c}^t\tilde{\boldsymbol{\tau}}$. Sin embargo, los estimadores $\mu + \tau_i$ no son únicos, en los dos casos se tiene:

$$(\hat{\mu}\mathbf{1} + \hat{\boldsymbol{\tau}})^t = (16, 18, 20) \quad y \quad (\tilde{\mu}\mathbf{1} + \tilde{\boldsymbol{\tau}})^t = \left(\frac{108}{7}, \frac{122}{7}, \frac{136}{7}\right).$$

Observación 7.2. Para la inversa generalizada de $\mathbf{\Omega}^{*-1}$ se satisface:

- $\mathbf{\Omega}^* \mathbf{1} = \mathbf{C} \mathbf{1} + n_{..}^{-1} \mathbf{r} \mathbf{r}^t \mathbf{1} = \mathbf{r}.$
- $\mathbf{\Omega}^{*-1} \mathbf{r} = \mathbf{1}.$
- $\mathbf{C} \mathbf{\Omega}^{*-1} \mathbf{C} = \mathbf{C}.$
- El vector solución obtenido con $\mathbf{\Omega}^{*-1}$ está sujeto a $\mathbf{r}^t \boldsymbol{\tau} = 0$, siempre que $\mathbf{r}^t \hat{\boldsymbol{\tau}} = \mathbf{r}^t \mathbf{\Omega}^{*-1} \mathbf{Q} = \mathbf{1}^t \mathbf{Q} = 0.$

Una vez obtenida la solución al sistema (7.16), se procede a llevar a cabo el análisis de la varianza, el cual se desarrolla a continuación.

7.7. Análisis de varianza

El interés se centra en la hipótesis de efecto de los tratamientos una vez se elimine el efecto de los bloques, es decir, se plantea la hipótesis de la forma $H_0 : \tau_1 = \tau_2 = \dots = \tau_t$. Para llevar a cabo la prueba anterior, se debe considerar la siguiente descomposición de la suma de cuadrados.

Sea $\mathbf{P}_0 = \mathbf{X}_0 (\mathbf{X}_0^t \mathbf{X}_0)^{-1} \mathbf{X}_0^t$ matriz de proyección ortogonal para la media, siendo $\mathbf{X}_0 = (\mathbf{1}_{(t \times b)})$ un vector de elementos iguales a uno.

De esta forma,

$$SC(\mu) = \mathbf{Y}^t \mathbf{X}_0 (\mathbf{X}_0^t \mathbf{X}_0)^{-1} \mathbf{X}_0^t \mathbf{Y} = \frac{y_{..}^2}{n_{..}}.$$

La suma de cuadrados de bloques es

$$SC_{Blok} = \mathbf{Y}^t (\mathbf{P}_{01} - \mathbf{P}_0) \mathbf{Y},$$

con $\mathbf{P}_{01} = \mathbf{X}_{01} (\mathbf{X}_{01}^t \mathbf{X}_{01})^{-1} \mathbf{X}_{01}^t$ matriz de proyección ortogonal para el espacio columna de bloques, siendo $\mathbf{X}_{01} = (\mathbf{D}_{t \times b, b})$ la matriz diseño para los bloques. De esta forma,

$$\begin{aligned} SC_{Blok} &= \mathbf{Y}^t \mathbf{P}_{01} \mathbf{Y} - \mathbf{Y}^t \mathbf{P}_0 \mathbf{Y} = \mathbf{B}^t \mathbf{K}^{-1} \mathbf{B} - \frac{G^2}{n_{..}} \\ &= \sum_{j=1}^b \frac{y_{.j}^2}{k_j} - \frac{y_{..}^2}{n_{..}}, \end{aligned}$$

y la suma de cuadrados total corregida es

$$SCT_{CM} = \mathbf{Y}^t (\mathbf{I} - \mathbf{P}_0) \mathbf{Y} = \sum_{i=1}^t \sum_{j=1}^b \sum_{m=1}^{n_{ij}} y_{ijm}^2 - \frac{y_{..}^2}{n_{..}}.$$

Teniendo esta descomposición, se procede a calcular la suma de cuadrados para los tratamientos ajustados $SCT_{rat} = T^t \hat{\tau}$, y teniendo esta suma de cuadrados, se obtiene la suma de cuadrados del error dada por:

$$\begin{aligned} SCE &= SCT_{CM} - SC_{Bloq} - SCT_{rat} \\ &= Y^t Y - \frac{G^2}{n_{..}} - B^t \hat{\beta} - T^t \hat{\tau}. \end{aligned}$$

De las ecuaciones normales y teniendo en cuenta que

$$\hat{\beta} = K^{-1} B - K^{-1} N^t \hat{\tau} - \mathbf{1} \hat{\mu},$$

al sustituir los estimadores, se encuentra que

$$\begin{aligned} SCE &= Y^t Y - \frac{G^2}{n_{..}} - B^t (K^{-1} B - K^{-1} N^t \hat{\tau} - \mathbf{1} \hat{\mu}) - T^t \hat{\tau} \\ &= Y^t Y - \frac{G^2}{n_{..}} - \left(B^t K^{-1} B - \frac{G^2}{n_{..}} \right) - (T^t - B^t K^{-1} N^t) \hat{\tau} \\ &= Y^t Y - B^t K^{-1} B - Q^t \hat{\tau}, \end{aligned}$$

donde $Q^t \hat{\tau}$ representa la suma de cuadrados ajustados de los tratamientos,

$$SCT_{rat_{ajus}} = Q^t \hat{\tau}. \quad (7.17)$$

Con estos resultados, se llega al siguiente estadístico de prueba para la hipótesis de interés:

$$F_c = \frac{\frac{Q^t \hat{\tau}}{t-1}}{\frac{SCE}{n_{..}-t-b+1}}.$$

Bajo H_0 se distribuye como $F_{(t-1, n_{..}-t-b+1)}$, rechazando H_0 si este valor es menor que el valor del estadístico, F_c .

Los resultados anteriores se resumen en la tabla 7.13 de análisis de varianza.

Ejemplo 7.5. Retomando los datos del ejemplo 7.4, si el interés es la hipótesis $H_0 : \tau_A = \tau_B = \tau_C$, se puede plantear la solución a partir de los resultados de la tabla 7.14 de análisis de varianza. A partir de esta tabla se observan algunos problemas como que la suma de cuadrados del error sea cero, lo cual no permite concluir acerca de H_0 .

Tabla 7.13: Análisis de varianza para cualquier estructura de bloques incompletos equilibrados

C de V	gl	SC	CM	F
Bloques	$b - 1$	$\mathbf{B}'\mathbf{K}^{-1}\mathbf{B} - \frac{G^2}{n_{..}}$	$\frac{SC_{B\log}}{b-1}$	
Tratamientos				
(Ajustados por bloque)	$t - 1$	$\mathbf{Q}'\hat{\tau}$	$\frac{SCTrat_{ajus}}{t-1}$	$\frac{CMTrat_{ajus}}{CME}$
Error	$n_{..} - t - b + 1$	$\mathbf{Y}'\mathbf{Y} - \mathbf{B}'\mathbf{K}^{-1}\mathbf{B} - \mathbf{Q}'\hat{\tau}$	$\frac{SCE}{n_{..}-t-b+1}$	
Total	$n_{..} - 1$	$\mathbf{Y}'\mathbf{Y} - \frac{G^2}{n_{..}}$		

Tabla 7.14: Análisis de varianza para los datos del ejemplo 7.4.

C de V	gl	SC	CM
Bloques	4	107.71	26.92
Tratamientos			
(Ajustados por bloque)	2	34.00	17.00
Error	7	0.00	0.00
Total	13	141.71	

La suma de cuadrados asociada con las respectivas fuentes de variación se obtiene realizando los siguientes procedimientos:

$$SC_{B\log} = \left(\frac{54^2}{4} + \frac{34^2}{2} + \frac{70^2}{4} + \frac{38^2}{2} + \frac{44^2}{2} \right) - \frac{240^2}{14}$$

$$= 4222 - 4114.29 = 107.71$$

$$SCTrat_{ajus} = \mathbf{Q}'\hat{\tau} = \begin{pmatrix} -9 & 1 & 8 \end{pmatrix} \begin{pmatrix} -2 \\ 0 \\ 2 \end{pmatrix} = 18 + 16 = 34$$

$$SCT_{CM} = \sum_{i=1}^3 \sum_{j=1}^5 \sum_{m=1}^{n_{ij}} y_{ijm}^2 - \frac{y_{...}^2}{n_{..}}$$

$$= 4256 - 4114.29 = 141.71.$$

Por consiguiente,

$$SCE = 141.71 - 107.71 - 34 = 0.$$

7.8. Diseño en bloques incompletos balanceados

En esta sección se lleva a cabo un breve desarrollo de los arreglos en bloques incompletos que vienen siendo por su aplicación más difundidos en la literatura estadística. Se resalta los diseños en bloques incompletos balanceados (DBIB), los cuales fueron introducidos por Yates (1936). Lo que caracteriza este arreglo del material experimental es lo siguiente:

- i. Cada bloque contiene k unidades experimentales.
- ii. Hay más tratamientos que unidades experimentales en un bloque.
- iii. Cada tratamiento aparece exactamente en r bloques.
- iv. Cada par de tratamientos ocurre justo en el mismo número de bloques λ veces.

Se considera el modelo (7.1) como un DBIB, en el cual

$$n_{ij} = \begin{cases} 1 & \text{si el tratamiento } i \text{ aparece en el bloque } j \\ 0 & \text{si el tratamiento } i \text{ no aparece en el bloque } j, \end{cases}$$

con $i = 1, \dots, t$ y $j = 1, \dots, b$ y $\lambda = \sum_{j=1}^b n_{ij}n_{i'j}$, para todo $i \neq i'$, $i, i' = 1, 2, \dots, t$, teniendo entonces que un DBIB está caracterizado por (b, t, r, k, λ) .

Las relaciones entre los parámetros b, t, r, k y λ son:

- i. $bk = tr = n_{..}$.
- ii. $\lambda = \frac{r(k-1)}{t-1}$.
- iii. $b \geq t$, llamada la desigualdad de Fisher.
- iv. Si $t = b$ y $r = k$, se dice que el diseño es simétrico.

La propiedad de que cada par de tratamientos aparezca junto λ veces hace posible que cualquier par de tratamientos sea comparable con el mismo error estándar.

Además, el balanceamiento facilita el análisis estadístico, ya que los totales de tratamiento se ajustan en una sola operación para el conjunto de bloques donde aparece el tratamiento i ($i = 1, 2, \dots, t$).

En este tipo de diseño, el análisis estadístico se centra en la información intrabloque, en la cual para estimar el efecto de los tratamientos se considera inicialmente la estimación de las parcelas dentro del mismo bloque.

Así, los efectos de tratamientos deben tener un proceso de ajuste. Con los tratamientos ajustados se lleva a cabo la estimación de los efectos de tratamientos.

Para poder llevar a cabo este análisis, se considera la estructura de la matriz $C = R - NK^{-1}N^t$, que en el caso balanceado tiene la forma siguiente:

$$\begin{aligned}
 C &= rI - \frac{1}{k}NN^t = rI - \frac{1}{k} \begin{pmatrix} \sum_{j=1}^b n_{1j}^2 & \cdots & \sum_{j=1}^b n_{1j}n_{tj} \\ \vdots & \ddots & \vdots \\ \sum_{j=1}^b n_{1j}n_{tj} & \cdots & \sum_{j=1}^b n_{tj}^2 \end{pmatrix} \\
 &= rI - \frac{1}{k} \begin{pmatrix} r & \lambda & \cdots & \lambda \\ \lambda & r & \cdots & \lambda \\ \vdots & \vdots & \ddots & \vdots \\ \lambda & \lambda & \cdots & r \end{pmatrix} = rI - \frac{1}{k}[(r - \lambda)I + \lambda J] \\
 &= \frac{\lambda t}{k}I - \frac{\lambda}{k}J = \frac{\lambda}{k}(tI - J), \tag{7.18}
 \end{aligned}$$

y así la matriz $\Omega = C + \frac{\lambda}{k}J = \frac{\lambda t}{k}I$, entonces $\Omega^{-1} = \frac{k}{\lambda t}I$.

Este resultado se observa del hecho que:

$$C\Omega^{-1}C = \left(\frac{\lambda t}{k}I - \frac{\lambda}{k}J\right) \left(\frac{k}{\lambda t}\right) \left(\frac{\lambda t}{k}I - \frac{\lambda}{k}J\right) = \frac{\lambda t}{k}I - \frac{\lambda}{k}J = C.$$

Obteniendo así finalmente la suma de cuadrados de los tratamientos ajustados como:

$$SCTrat_{ajus} = Q^t \hat{\tau} = Q^t \Omega^{-1} Q = \frac{k}{\lambda t} Q^t Q \tag{7.19}$$

$$= \frac{k}{\lambda t} \sum_{i=1}^t \left(y_{i..} - \sum_{j=1}^b \frac{n_{ij}y_{.j.}}{k} \right)^2 = \frac{k}{\lambda t} \sum_{i=1}^t Q_i^2, \tag{7.20}$$

donde $Q_i = y_{i..} - \sum_{j=1}^b \frac{n_{ij}y_{.j.}}{k}$.

En los experimentos con bloques incompletos es importante determinar el factor de eficiencia, el cual se calcula a partir de la expresión:

$$E = \frac{\lambda t}{kr} = \frac{\frac{2}{r}CME}{\frac{2k}{\lambda t}CME}, \quad 0 < E < 1,$$

donde CME es la estimación de la varianza residual. Por otro lado, la estimación de la varianza de la diferencia entre la estimación de medias de dos tratamientos es:

$$V(\hat{\mu}_i - \hat{\mu}_{i'}) = \frac{2CME}{r},$$

lo cual conlleva a que se recomienden bloques completos.

En el caso de bloques incompletos equilibrados,

$$V(\hat{\mu}_i - \hat{\mu}_{i'}) = \frac{2CME}{rE}.$$

Por lo tanto, si $E \rightarrow 0$, se tiene menor precisión en las estimaciones bajo bloques incompletos balanceados, y si $E \rightarrow 1$, se deben preferir bloques incompletos balanceados.

Ejemplo 7.6. *Suponga que un ingeniero químico piensa que el tiempo de reacción de un proceso químico es una función del tipo de catalizador empleado. Se están investigando cuatro catalizadores, en cuatro lotes de materia prima, y se observa el tiempo de reacción (Montgomery 2003). Los datos obtenidos se presentan en la tabla 7.15.*

Tabla 7.15: Tiempos de reacción del proceso

Catalizador	Lote de materia prima				$y_{i.}$
	I	II	III	IV	
1	73	74	-	71	218
2	-	75	67	72	214
3	73	75	68	-	216
4	75	-	72	75	222
$y_{.j}$	221	224	207	218	$y_{..} = 870$

En este conjunto de datos, se tiene $r = 3$, $k = 3$ y el número de veces que cada par de tratamientos aparece en el mismo bloque es:

$$\lambda = \frac{r(k-1)}{t-1} = \frac{3(2)}{3} = 2.$$

Este diseño en bloques incompletos balanceado tiene una eficiencia relativa con respecto al DBCA de

$$E = \frac{\lambda t}{kr} = \frac{2(4)}{3(3)} = \frac{8}{9} = 0.889,$$

lo que hace preferir bloques incompletos balanceados.

Para comprobar la hipótesis $H_0 : \tau_1 = \tau_2 = \tau_3 = \tau_4$, se construyen las diferentes sumas de cuadrados con base en la estructura de las siguientes matrices:

$$C = \frac{2}{3}(4I_{4 \times 4} - J_{4 \times 4}), \quad \Omega = \frac{8}{3}I_{4 \times 4} \quad y \quad \Omega^{-1} = \frac{3}{8}I_{4 \times 4}.$$

Además, en este caso se tiene que

$$\mathbf{Q} = \begin{pmatrix} Q_1 \\ Q_2 \\ Q_3 \\ Q_4 \end{pmatrix} = \begin{pmatrix} 218 - \frac{1}{3}(221 + 224 + 218) \\ 214 - \frac{1}{3}(207 + 224 + 218) \\ 216 - \frac{1}{3}(221 + 207 + 224) \\ 222 - \frac{1}{3}(221 + 207 + 218) \end{pmatrix} = \frac{1}{3} \begin{pmatrix} -9 \\ -7 \\ -4 \\ 20 \end{pmatrix}$$

y

$$\hat{\tau} = \mathbf{\Omega}^{-1} \mathbf{Q} = \frac{3}{2(4)} \frac{1}{3} \begin{pmatrix} -9 \\ -7 \\ -4 \\ 20 \end{pmatrix} = \frac{1}{8} \begin{pmatrix} -9 \\ -7 \\ -4 \\ 20 \end{pmatrix}.$$

Con base en estos resultados, se encuentra que:

$$SCT_{CM} = \sum_{ij} y_{ij}^2 - \frac{y_{..}^2}{12} = 63.16 - \frac{(870)^2}{12} = 81.00$$

$$\begin{aligned} SC_{Bloq} &= \frac{1}{3} \sum_{j=1}^4 y_{.j}^2 - \frac{y_{..}^2}{12} \\ &= \frac{1}{3} [(221)^2 + (207)^2 + (224)^2 + (218)^2] - \frac{870^2}{12} = 55.00 \end{aligned}$$

$$SCT_{rat_{ajus}} = \mathbf{Q}^t \hat{\tau} = \frac{1}{24} (81 + 49 + 16 + 400) = 22.75.$$

Finalmente,

$$SCE = SCT_{CM} - SCT_{rat_{ajus}} - SC_{Bloq} = 81.00 - 22.75 - 55.00 = 3.25.$$

En la tabla 7.16 se resumen los resultados anteriores a través del análisis de varianza. Puesto que $F_c = 11.66 > F_{(3,5,0.05)} = 5.41$, se concluye que el catalizador empleado tiene un efecto significativo sobre el tiempo de reacción.

Tabla 7.16: Análisis de varianza para los tiempos de reacción del proceso

C de V	gl	SC	CM	F	Valor p
Bloques	3	55.00	18.33		
Tratamientos (ajustados por bloques)	3	22.75	7.58	11.66	0.01
Error	5	3.25	0.65		
Total	11	81.00			

En ocasiones existe interés en evaluar los efectos de los bloques. Para ello se requiere hacer una partición alternativa de SCT_{CM} haciendo uso de las ecuaciones normales (7.14), es decir,

$$\begin{aligned}
SCT_{CM} &= Y^t Y - \frac{G^2}{n_{..}} = B^t \hat{\beta} + T^t \hat{\tau} + SCE \\
&= B^t \hat{\beta} + T^t R^{-1} (T - N \hat{\beta} - 1 \hat{\mu}) + SCE \\
&= (B^t - T^t R^{-1} N) \hat{\beta} + T^t (R^{-1} T - 1 \hat{\mu}) + SCE \\
&= Q^{*t} \hat{\beta} + \left(T^t R^{-1} T - \frac{G^2}{n_{..}} \right) + SCE \\
&= SCB_{loq_{ajus}} + SCT_{rat} + SCE,
\end{aligned}$$

donde $Q^{*t} = B^t - T^t R^{-1} N$. En este caso, $\hat{\tau} = R^{-1} (T - N \hat{\beta} - 1 \hat{\mu})$.

Del sistema (7.15), al hacer $Q^* = B - N^t R^{-1} T$ y $C^* = K - N^t R^{-1} N$, se expresa la ecuación c. como:

$$Q^* = C^* \hat{\beta},$$

donde Q^* es el vector de totales de bloques ajustados,

$$\begin{aligned}
Q^* &= \begin{pmatrix} B_1 \\ B_2 \\ \vdots \\ B_b \end{pmatrix} - \begin{pmatrix} n_{11} & n_{21} & \cdots & n_{t1} \\ n_{12} & n_{22} & \cdots & n_{t2} \\ \vdots & \vdots & \ddots & \vdots \\ n_{1b} & n_{2b} & \cdots & n_{tb} \end{pmatrix} \begin{pmatrix} \frac{1}{r_1} & 0 & \cdots & 0 \\ 0 & \frac{1}{r_2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \frac{1}{r_t} \end{pmatrix} \begin{pmatrix} T_1 \\ T_2 \\ \vdots \\ T_t \end{pmatrix} \\
&= \begin{pmatrix} Q_1^* \\ Q_2^* \\ \vdots \\ Q_b^* \end{pmatrix} = \begin{pmatrix} B_1 - \sum_{i=1}^t \frac{n_{i1} T_i}{r_i} \\ B_2 - \sum_{i=1}^t \frac{n_{i2} T_i}{r_i} \\ \vdots \\ B_b - \sum_{i=1}^t \frac{n_{ib} T_i}{r_i} \end{pmatrix} = \begin{pmatrix} y_{1.} - \sum_{i=1}^t \frac{n_{i1} y_{i..}}{r_i} \\ y_{2.} - \sum_{i=1}^t \frac{n_{i2} y_{i..}}{r_i} \\ \vdots \\ y_{b.} - \sum_{i=1}^t \frac{n_{ib} y_{i..}}{r_i} \end{pmatrix},
\end{aligned}$$

con $Q_j^* = B_j - \sum_{i=1}^t \frac{n_{ij} T_i}{r_i}$ el total del bloque j ajustado por tratamiento.

Para poder llevar a cabo este análisis, se considera la estructura de la matriz $C^* = K - N^t R^{-1} N$, que en el caso balanceado tiene la siguiente estructura:

$$C^* = kI - \frac{1}{r} [(k - \lambda)I + \lambda J] = \frac{\lambda b}{r} I - \frac{\lambda}{r} J = \frac{\lambda}{r} (bI - J).$$

De este modo, la matriz $\Omega_* = C^* + \frac{\lambda}{r} J = \frac{\lambda b}{r} I$, entonces $\Omega_*^{-1} = \frac{r}{\lambda b} I$.

Obteniendo, así, finalmente la suma de cuadrados de los bloques ajustados como:

$$\begin{aligned} SCBloq_{ajus} &= \mathbf{Q}^{*t} \hat{\boldsymbol{\beta}} = \mathbf{Q}^{*t} \boldsymbol{\Omega}_*^{-1} \mathbf{Q}^* = \frac{r}{\lambda b} \mathbf{Q}^{*t} \mathbf{Q}^* \\ &= \frac{r}{\lambda b} \sum_{j=1}^b \left(y_{\cdot j} - \sum_{i=1}^t \frac{n_{ij} y_{i\cdot}}{r} \right)^2 = \frac{r}{\lambda b} \sum_{j=1}^b Q_j^{*2}, \end{aligned}$$

donde $Q_j^* = y_{\cdot j} - \sum_{i=1}^t \frac{n_{ij} y_{i\cdot}}{r}$.

Ejemplo 7.7. Se tiene interés en comprobar la hipótesis $H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4$ en los datos del ejemplo 7.6. Para ello, se construyen las diferentes sumas de cuadrados con base en la estructura de las siguientes matrices:

$$\mathbf{C}^* = \frac{2}{3}(4\mathbf{I}_{4 \times 4} - \mathbf{J}_{4 \times 4}), \quad \boldsymbol{\Omega}_* = \frac{8}{3}\mathbf{I}_{4 \times 4} \quad y \quad \boldsymbol{\Omega}_*^{-1} = \frac{3}{8}\mathbf{I}_{4 \times 4}.$$

Además,

$$\mathbf{Q}^* = \begin{pmatrix} Q_1^* \\ Q_2^* \\ Q_3^* \\ Q_4^* \end{pmatrix} = \begin{pmatrix} 221 - \frac{1}{3}(218 + 216 + 222) \\ 224 - \frac{1}{3}(218 + 214 + 216) \\ 207 - \frac{1}{3}(214 + 216 + 222) \\ 218 - \frac{1}{3}(218 + 214 + 222) \end{pmatrix} = \frac{1}{3} \begin{pmatrix} 7 \\ 24 \\ -31 \\ 0 \end{pmatrix}$$

y

$$\hat{\boldsymbol{\beta}} = \boldsymbol{\Omega}_*^{-1} \mathbf{Q}^* = \frac{3}{2(4)} \frac{1}{3} \begin{pmatrix} 7 \\ 24 \\ -31 \\ 0 \end{pmatrix} = \frac{1}{8} \begin{pmatrix} 7 \\ 24 \\ -31 \\ 0 \end{pmatrix}.$$

De esta manera, se llega a

$$SCBloq_{ajus} = \mathbf{Q}^{*t} \hat{\boldsymbol{\beta}} = \frac{1}{24} [(7)^2 + (24)^2 + (-31)^2 + (0)^2] = 66.08$$

$$\begin{aligned} SCTrat &= \frac{1}{3} \sum_{i=1}^4 y_{i\cdot}^2 - \frac{y_{\cdot\cdot}^2}{12} \\ &= \frac{1}{3} [(218)^2 + (214)^2 + (216)^2 + (222)^2] - \frac{(870)^2}{12} = 11.67. \end{aligned}$$

En la tabla 7.17, se resumen los resultados anteriores. De esta se concluye que los lotes de materia prima (bloques) difieren de manera significativa sobre el tiempo de reacción, puesto que $F_c = 33.90 > F_{(3,5,0.05)} = 5.41$.

Tabla 7.17: Análisis de varianza para los tiempos de reacción del proceso (Bloques ajustados por tratamientos)

C de V	gl	SC	CM	F	Valor p
Tratamientos	3	11.67	3.89		
Bloques (ajustados por tratamientos)	3	66.08	22.03	33.90	0.00
Error	5	3.25	0.65		
Total	11	81.00			

Con el fin de llevar a cabo métodos de cálculos más cortos, se dividen los diseños en bloques incompletos balanceados en cinco tipos (Cochran y Cox 1974):

- **Tipo I:** experimentos en que los bloques pueden ser agrupados por repeticiones. Hay menor precisión de efectos de tratamientos y se disminuyen unidades experimentales dentro de los bloques, es decir, se obtienen bloques más homogéneos.
- **Tipo II:** experimentos en que los bloques pueden agruparse en grupos de repeticiones. En estos arreglos, aunque se pierden grados de libertad en el error, lo que conlleva a una menor precisión del experimento, se gana en reducción del tamaño del experimento.
- **Tipo III:** experimentos en los que los bloques no pueden ser agrupados en repeticiones o grupos de repeticiones. En este caso, se gana en precisión, pero se pierde homogeneidad.
- **Tipo IV:** experimentos con $t = b$, o sea, el número de tratamientos igual al número de bloques.
- **Tipo V:** son útiles estos arreglos cuando se tienen pequeños experimentos con pocas parcelas. En estos experimentos, el número de grados de libertad asociados con los cuadrados medios para los bloques y el error intrabloque es pequeño. Por tanto, las estimaciones no son lo suficientemente confiables estadísticamente.

En el volumen dos se tratan en mayor detalle estos tipos de DBIB.

7.8.1. Estimación de datos faltantes

La expresión para la estimación de datos faltantes en diseños en bloques incompletos puede estudiarse en Cochran y Cox (1974), en donde se cita el trabajo de Cornish, quien en 1940 desarrolló métodos de estimación de

datos perdidos en bloques incompletos balanceados. Para ello, utilizó como criterio de minimización la suma de cuadrados del error intrabloque.

En caso de tener una observación faltante en la estructura de los bloques incompletos, la expresión obtenida de esta minimización fue

$$\hat{x} = \frac{tr(k-1)B_j + k^2(t+1)Q_i - k(t-1)Q'}{(k-1)[tr(k-1) - k(t-1)]},$$

siendo B_j el total del bloque que contiene la observación perdida, $Q_i = T_i - \frac{B_t}{k}$ para el tratamiento que tiene el dato perdido, Q' la suma de los valores de Q para todos los tratamientos que están en el bloque con el valor perdido y B_t la suma de los totales de bloque donde está el tratamiento al que pertenece el valor perdido.

7.8.2. Método de Scheffé para comparaciones múltiples

Scheffé (1953) hace una propuesta para comparar algunos de los posibles contrastes entre medias de tratamientos. Esta prueba de comparación múltiple de medias es recomendable en arreglos con bloques incompletos.

El método supone un conjunto de contrastes $L = \sum_{i=1}^t a_i \mu_i$, el cual tiene como estimador $\hat{L} = \sum_{i=1}^t a_i \bar{y}_i$, y error estándar

$$S_0 = \sqrt{CME \sum_{i=1}^t \frac{a_i^2}{n_i}},$$

como se presentó en la sección 6.1.2 del capítulo 6.

En bloques incompletos, la implementación de contrastes ortogonales debe ser hecha con los totales de tratamiento ajustados. En el caso balanceado, la suma de cuadrados del contraste de medias para los tratamientos ajustados es:

$$SC_C = \frac{k \left(\sum_{i=1}^t a_i Q_i \right)^2}{\lambda t \sum_{i=1}^t a_i^2}.$$

Con un error estándar igual a

$$S_C = \frac{\sqrt{kCME \sum_{i=1}^t a_i^2}}{\lambda r}.$$

Bajo $H_0 : L = 0$, nuevamente el criterio de decisión se hace considerando

$$S = S_C F_0 = S_C \sqrt{(t-1)F_{(t-1, n-t, \alpha)}}.$$

Al igual que lo planteado en el capítulo 6, si $|\hat{L}| > S$, entonces la hipótesis $H_0 : L = 0$ es rechazada.

Ejemplo 7.8. Retomando los datos del ejemplo 7.6, si se pierde el dato correspondiente al catalizador uno del lote IV, no se tendría un diseño en bloque balanceado, pero cuando se realiza una estimación del mismo se encuentra:

$$\begin{aligned}\hat{x} &= \frac{4(3)(2)(147) + 9(5) \left(147 - \frac{445}{3}\right) - 3(3) \left(214 - \frac{431}{3} + 222 - \frac{428}{3}\right)}{(2)[4(3)(2) - 3(3)]} \\ &= 70.7,\end{aligned}$$

que se aleja muy poco de la observación real, en este caso, 71.

Ahora, si se plantea la hipótesis $H_0 : \tau_1 = \tau_2$, se obtiene que:

$$\begin{aligned}\hat{L} = \bar{y}_{1.} - \bar{y}_{2.} &= \frac{218}{3} - \frac{214}{3} = \frac{4}{3} \\ S_C &= \frac{\sqrt{3(0.65)(2)}}{2(3)} = 0.33.\end{aligned}$$

Entonces, como $S_C = (0.33)\sqrt{(3)F_{(3,8,0.05)}} = 1.15$ es menor que 1.33, no hay evidencias para rechazar H_0 . Por lo tanto, se concluye que los dos catalizadores tienen el mismo efecto sobre el tiempo de reacción.

7.9. Implementación en SAS

A partir de los datos de los ejemplos 7.1, 7.3, 7.5 y 7.6, se presentan a continuación los programas en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos.

```
/* Diseño en bloques completamente aleatorizado */
DATA EJEMPLO71; /*archivo del ejemplo 7.1*/
DO TRATAMIENTO=1 TO 6;
  DO SUELO=1 TO 4;
    PRODUCCION @@; OUTPUT;
  END;
END;
CARDS; /* Ingreso de datos */
32.1 35.6 41.9 35.4
30.1 31.5 37.1 30.8
```

```

25.4 27.1 33.8 31.1
24.1 33.0 35.6 31.4
26.1 31.0 33.8 31.9
23.2 24.8 26.7 26.7
;

```

```

/* Obtención del análisis de varianza */
PROC GLM DATA=EJEMPLO71;
CLASS TRATAMIENTO SUELO; /*Se clasifica por TRATAMIENTO y SUELO*/
/* Con las opción SS1 y SS3 se obtienen las sumas de cuadrados,
SS3 es de interés si se desea hacer alguna inferencia sobre
el bloque*/
MODEL PRODUCCION=TRATAMIENTO SUELO/SS1 SS2;
/* Se obtienen las pruebas de DUNCAN SCHEFFE TUKEY de
comparaciones no \linebreak planeadas*/
MEANS TRATAMIENTO/DUNCAN SCHEFFE TUKEY;
LSMEANS TRATAMIENTO; /*Se obtienen la media y la desviación estándar*/

```

```

/* Diseño en bloques completamente aleatorizado con
submuestreo*/

```

```

DATA EJEMPLO73; /*archivo del ejemplo 7.3*/
DO TIEMPO=0 TO 2;
  DO REP=1 TO 2;
    DO NITROGENO=1 TO 3;
      INPUT CANTIDAD @@;OUTPUT;
    END;\\
  END;\\
END;\\
CARDS; /*ingreso de datos*/
2.29 6.80 8.75
2.54 5.94 9.52
0.46 3.03 2.49
0.19 1.00 2.04
0.00 0.75 1.40
0.26 1.16 1.81
;

```

```

/* Obtención del análisis de varianza */
PROC GLM DATA=EJEMPLO73;
CLASS TIEMPO NITROGENO;
MODEL CANTIDAD=TIEMPO NITROGENO TIEMPO*NITROGENO;
RANDOM TIEMPO*NITROGENO/TEST;

```

```

/*Se define el error experimental como la interacción TIEMPO*NITROGENO*/

```

```

/* Análisis de varianza y estimación de las componentes
de varianza*/
PROC MIXED DATA=EJEMPLO73;
CLASS TIEMPO NITROGENO;

```

```

MODEL CANTIDAD=TIEMPO NITROGENO;
/*Se define el error experimental como la interacción TIEMPO*NITROGENO*/
RANDOM TIEMPO*NITROGENO; /*Por defecto el error de
submuestreo es el que aparece en la salida como error*/

/* Diseño en bloques incompletos*/
DATA EJEMPL075; /*archivo del ejemplo 7.5*/
INPUT BLOQUE TRATAMIENTO Y @@;
CARDS;
  1 1 12 1 1 12 1 2 14 1 3 16
  2 2 16 2 3 18
  3 1 16 3 1 16 3 2 18 3 3 20
  4 1 18 4 2 20
  5 1 20 5 3 24
;

PROC GLM DATA=EJEMPL075;
CLASS BLOQUE TRATAMIENTO;

/* Con las opción SS3 si se desea hacer alguna
inferencia sobre los bloque y los tratamientos*/
MODEL Y=BLOQUE TRATAMIENTO/SS1 SS3;

/* Se obtiene las prueba Scheffé de comparaciones no
planeadas*/
MEANS TRATAMIENTO/SCHEFFE;

/* Diseño en bloques incompletos balanceado*/
DATA EJEMPL076; /*archivo del ejemplo 7.6*/
INPUT CATALIZADOR LOTE TIEMPO @@;
CARDS;
  1 1 73 1 2 74 1 3 . 1 4 71
  2 1 . 2 2 75 2 3 67 2 4 72
  3 1 73 3 2 75 3 3 68 3 4 .
  4 1 75 4 2 . 4 3 72 4 4 75
;

PROC GLM DATA=EJEMPL076;
CLASS LOTE CATALIZADOR;
MODEL TIEMPO=LOTE CATALIZADOR/SS1 SS3;
MEANS CATALIZADOR/SCHEFFE;
RUN;

```

7.10. Implementación en R

A partir de los datos de los ejemplos [7.1](#), [7.3](#), [7.5](#) y [7.6](#), se presenta a continuación el programa en el software estadístico R.

```
#####
## Ejemplo 7.1 ##
#####
```

```
#Introducción de los datos del ejemplo
ejemplo7.1<-data.frame(suelo=factor(c(rep(1,6),rep(2,6),rep(3,6),rep(4,6))),
fuente=factor(c(rep(seq(1,6),4))),produccion=c(32.1,30.1,25.4,24.1,26.1,
23.2,35.6,31.5,27.1,33.0,31.0,24.8,41.9,37.1,33.8,35.6,33.8,26.7,35.4,30.8,
31.1,31.4,31.9,26.7))
```

```
anova7.1 <- aov(produccion ~ suelo+fuente,contrasts=list(fuente="contr.sum",
suelo="contr.sum"),data=ejemplo7.1)
summary(anova7.1)
summary(lm(anova))
```

```
boxplot(produccion~fuente, data=ejemplo7.1, id=list(method="y"))
```

```
library(agricolae)
# Prueba de Duncan
duncan.test(anova7.1,"fuente", group=TRUE,console=TRUE,main="Fuente")
```

```
# Prueba de Scheffe
scheffe.test(anova7.1,"fuente",group=TRUE,console=TRUE,main="Fuente")
```

```
# Prueba de Tukey
TukeyHSD(anova7.1,"fuente")
```

```
tabla.medias <- model.tables(anova7.1, type = "mean")
media.dietas <- mean(tabla.medias$tables$fuente)
```

```
#####
## Ejemplo 7.2 ##
#####
```

```
##Cálculo del dato faltante
dbca.matriz<-matrix(ejemplo7.1$produccion,6,4)
dbca.matriz[dbca.matriz==37.1]<-NA
dbca.matriz
```

```
xFalt<-37.1
t<-6
b<-4
library(stats)
y.jasterisco<-sum(dbca.matriz[,3],na.rm=T)
y.jasterisco
yi.asterisco<-sum(dbca.matriz[2,],na.rm=T)
yi.asterisco
y..asterisco<-sum(dbca.matriz[,],na.rm=T)
```

```

# estimación del dato faltante
x.est<-(t*yi.asterisco+b*y.jasterisco-y..asterisco)/((t-1)*(b-1))

# Cuadrado medio de bloques
CMB <- 64.25
#desviación estándar
s<-sqrt(sum((anova7.1$residuals)^2)/anova7.1$df.residual)
# Cuadrado medio del error
CME<-s^2

# Eficiencia relativa
ER<-1+(1/t)*((CMB/CME)-1)
ER

#####
## Ejemplo 7.3 ##
#####

ejemplo7.3 <- data.frame(tiempo=factor(c(rep(1,6),rep(2,6),rep(3,6))),
nitrogeno=factor(c(rep(seq(1,3),6))),
cantidad=c(2.29,6.80,8.75,2.54,5.94,9.52,0.46,
3.03,2.49,0.19,1.00,2.04,0.00,0.75,1.40,0.26,1.16,1.81),
sujeto=factor(c(rep(c(1,2,3),2),rep(c(4,5,6),2),rep(c(7,8,9),2))))

anova7.3<-aov(cantidad~tiempo+nitrogeno+
Error(tiempo:nitrogeno),data=ejemplo7.3)
summary(anova7.3)

dca1<-aov(cantidad~tiempo+nitrogeno+Error(sujeto),data=ejemplo7.3)
summary(dca1)

library(EMSaov)
EMSanova(cantidad~tiempo+nitrogeno, data=ejemplo7.3, type = c("R", "R"),
nested = c(NA, NA), level = c(3, 3))

# residuales del modelo para validación de supuestos
res <- anova7.3$residuals
# varianza del error experimental
varee<-1/2*(4.2893-0.3441)
vartotal<-varee+0.3441
# coeficiente de correlación intraclase del error experimental
r1 <- varee/vartotal
r1
# coeficiente de correlación intraclase del error muestral
r2 <- 0.3441/vartotal
r2

```

```
#####
## Ejemplo 7.4 ##
#####
```

```
R <- diag(c(6,4,4),3)
K <- diag(c(4,2,4,2,2),5)
N <- matrix(c(2,1,1,0,1,1,2,1,1,1,0,1,0,1),nrow=3,byrow=F)
C <- R-N%%solve(K)%*%t(N)
B <- matrix(c(54,34,70,38,44),nrow=5,byrow=F)
T <- matrix(c(94,68,78),nrow=3,byrow=F)
Q <- T-N%%solve(K)%*%B
J <- matrix(1:1,nrow=3,ncol=3, byrow=T)
omega <- C+3/2*J
inversaomega <- solve(omega)
taoestimado <- inversaomega%%Q
uno <- matrix(1,nrow=5,ncol=1)
t(uno)%*%solve(K)%*%B
t(uno)%*%solve(K)%*%t(N)%*%taoestimado
t(uno)%*%uno
miuestimado <- (t(uno)%*%solve(K)%*%B-t(uno)%*%solve(K)%*%t(N)%*%
taoestimado)/(t(uno)%*%uno)
betaestimado <- solve(K)%*%(B-K%*%uno%*%miuestimado-t(N)%*%taoestimado)
r <- diag(R)
n.. <- sum(N)
rrt <- r%*%t(r)
omegaast <- C+(r%*%t(r))/n..
inversaomegaast <- solve(omegaast)
taoestimado1 <- inversaomegaast%%Q
t(uno)%*%solve(K)%*%t(N)%*%taoestimado1
miuestimado1 <- 120/7
betaestimado1 <- solve(K)%*%(B-K%*%uno%*%miuestimado1-t(N)%*%taoestimado1)
miuunomastaot <- t(matrix(18,nrow=3,ncol=1)+taoestimado)
miuunomastaot1 <- t(matrix(120/7,nrow=3,ncol=1)+taoestimado1)
```

```
#####
## Ejemplo 7.5 ##
#####
```

```
#Introducción de los datos del ejemplo
ejemplo7.5 <- data.frame(bloque=factor(c(1,1,1,1,2,2,3,3,3,3,4,4,5,5)),
tratamiento=factor(c(1,1,2,3,2,3,1,1,2,3,1,2,1,3)),
resultados=c(12,12,14,16,16,18,16,16,18,20,18,20,20,24))
```

```
anova7.5 <- aov(resultados ~ bloque + tratamiento,data=ejemplo7.5)
summary(anova7.5)
```

```
SCTrajustado <- t(Q)%*%taoestimado
SCTrajustado1 <- t(Q)%*%taoestimado1
```

```

# Prueba de Scheffe
scheffe.test(anova7.5,"tratamiento",group=TRUE,console=TRUE,
main="Tratamiento")

#####
## Ejemplo 7.6 ##
#####

#Introducción de los datos del ejemplo
ejemplo7.6 <- data.frame(lote=factor(c(1,1,1,2,2,2,3,3,3,4,4,4)),
catalizador=factor(c(1,3,4,1,2,3,2,3,4,1,2,4)),
tiempo=c(73,73,75,74,75,75,67,68,72,71,72,75))

anova7.6 <- aov(tiempo ~ lote + catalizador,data=ejemplo7.6)
summary(anova7.6)

# Prueba de Scheffe
scheffe.test(anova7.6,"catalizador",group=TRUE,console=TRUE,
main="Catalizador")

# cada tratamiento aparece en 3 bloques
r <- 3
# cada bloque contiene 3 unidades experimentales
k <- 3
# número de tratamientos
t <- 4
lambda <- r*(k-1)/(t-1)

# Eficiencia relativa
ER <- lambda*t/(k*r)
R <- diag(c(3,3,3,3),4)
K <- diag(c(3,3,3,3),4)
N <- matrix(c(1,0,1,1,1,1,1,0,0,1,1,1,1,0,1),nrow=4,byrow=F)
inversaK<-solve(K)
NinversaKtN<-N%%inversaK%%t(N)
C <- R-N%%solve(K)%%t(N)
# I <- diag(4)
# J <- matrix(1:1,nrow=4,ncol=4, byrow=T)
# C <- 2/3*(4*I-J)
T <- matrix(c(218,214,216,222),nrow=4,byrow=F)
B <- matrix(c(221,224,207,218),nrow=4,byrow=F)
NinversaK<-N%%inversaK
NinversaKB<-N%%inversaK%%B
Q <- T-N%%solve(K)%%B
J <- matrix(1:1,nrow=4,ncol=4, byrow=T)
omega <- C+J
taoestimado <- solve(omega)%%Q
SCTrajustado <- t(Q)%%taoestimado

```



```
#####
## Ejemplo 7.7 ##
#####

# Bloques ajustados por tratamientos
anova7.7 <- aov(tiempo ~ catalizador + lote,data=ejemplo7.6)
summary(anova7.7)

# Prueba de Scheffe
scheffe.test(anova7.7,"catalizador",group=TRUE,console=TRUE,
main="Catalizador")

Qast <- B-t(N)%*%solve(R)%*%T
Cast <- K-t(N)%*%solve(R)%*%N
J <- matrix(1:1,nrow=4,ncol=4, byrow=T)
omegaast <- Cast+J
betaestimado <- solve(omegaast)%*%Qast
SCBaju <- t(Qast)%*%betaestimado

library(car)
Anova(anova7.7, type="II")
Anova(anova7.7, type="III", singular.ok=T)
```

7.11. Ejercicios

1. Considere un experimento de 10 tratamientos y 5 replicaciones en el diseño experimental de bloques completos aleatorizados. Muestre un plan de la aleatorización de los tratamientos en las réplicas (bloques).
2. 15 variedades de maíz fueron sembradas en una estación experimental, con el propósito de seleccionar las de mayor producción. El ensayo se realizó teniendo en cuenta una estructura de bloques. Se midió el *rendimiento de maíz (tonelada / unidad de superficie)*, los resultados del ensayo se resumen en la siguiente tabla:

C de V	gl	SC	CM	Fc
Bloques	2			
Variedades			38033.14	7.38
Error				
Total		7082935		

- a. Pruebe la hipótesis $H_0 : \tau_1 = \dots = \tau_{15}$ al nivel de significación $\alpha = 0.01$.

b. Sean las siguientes medias de tratamientos:

$$\begin{array}{lll} \bar{y}_{1.} = 830.0 & \bar{y}_{6.} = 628.7 & \bar{y}_{11.} = 533.0 \\ \bar{y}_{2.} = 814.3 & \bar{y}_{7.} = 625.7 & \bar{y}_{12.} = 530.0 \\ \bar{y}_{3.} = 792.0 & \bar{y}_{8.} = 597.3 & \bar{y}_{13.} = 528.3 \\ \bar{y}_{4.} = 685.0 & \bar{y}_{9.} = 592.3 & \bar{y}_{14.} = 515.3 \\ \bar{y}_{5.} = 660.7 & \bar{y}_{10.} = 560.7 & \bar{y}_{15.} = 492.0 \end{array}$$

Usando la *prueba de Duncan*, genere grupos iguales de efectos de tratamientos.

- c. Si las variedades 1 a 5 son procedentes de Centro América y las variedades 6, 7 y 8 son procedentes de USA, lleve a cabo una prueba para determinar si el rendimiento medio de las variedades USA es igual al rendimiento medio de las variedades de Centro América.
- d. Suponga que se perdió la información en el segundo bloque, tercera variedad, y en el primer bloque, quinta variedad, ¿cómo llevaría a cabo el análisis en este caso? Presente la tabla ANOVA.
- e. Si usted quisiera controlar otra fuente natural de variación del material experimental, ¿qué modelo propondría y por qué? ¿Qué inconvenientes tendrá el modelo propuesto?

3. Con base en los resultado obtenidos en el ejercicio 11 del capítulo 3,

- a. Describa como probar $H_0 : \tau_1 = \tau_2 = \tau_3 = \tau_4 = \tau_5$.
- b. Si S_i^2 es la suma de cuadrados para probar $H_0 : \gamma_i = 0, i = 1, \dots, 4$, muestre que $S^2 = S_1^2 + S_2^2 + S_3^2 + S_4^2$ es la suma de cuadrados para probar H_0 de la parte a., $H_0 : \gamma_i = 0$, donde

$$F = \frac{\delta}{CME}, \text{ con } \delta = \frac{\left(\sum_{i=1}^t k_i \bar{y}_{i.} \right)^2}{\sum_{i=1}^t k_i^2 / n_i}, \text{ la suma de cuadrados de la hipótesis.}$$

4. Considere el modelo: $y_{ijk} = \mu + \alpha_i + \beta_j + \epsilon_{ijk}$, con $i = 1, 2, \dots, t$, $j = 1, 2, \dots, b$ y $k = 1, 2, \dots, r$.

- a. Escriba el modelo en forma matricial.
- b. Obtenga $SC(\alpha)$, $SC(\beta)$, $SC(\epsilon)$ y SCT_{CM} .
- c. Encuentre $E[Y^t P_\alpha Y]$ y $E[Y^t P_\beta Y]$.
- d. Lleve a cabo el análisis de la varianza.

5. El peso neto en onzas de albaricoques congelados fue medido para varios tipos y diversas concentraciones de jarabe. Los pesos originales de los albaricoques eran iguales, las diferencias en el peso neto debían atribuirse a diferencias en las concentraciones o en el tipo de jarabe (Martínez 1981). Los resultados se resumen en la siguiente tabla:

Concen- tración de jarabe	Composición del Jarabe			
	Todo sucioso (τ_1)	2/3 sucioso y 1/3 jarabe granular (τ_2)	1/2 sucioso y 1/2 jarabe granular (τ_3)	Todo jarabe granular (τ_4)
30	28.80	X_1	29.28	29.12
40	29.12	28.64	29.12	X_2
50	29.76	30.40	29.12	28.32
65	30.56	29.44	28.96	29.60

Suponiendo que el material experimental se arregló en bloques, en los que el bloqueo se hizo teniendo en cuenta la concentración del jarabe.

- Si X_1 y X_2 son unidades perdidas, lleve a cabo una estimación de estas unidades.
 - Realice las siguientes comparaciones de interés para la conclusión del experimento:
 - τ_1 vs τ_4 .
 - τ_1 vs $1/2(\tau_2 + \tau_3)$.
 - τ_4 vs $1/2(\tau_2 + \tau_3)$.
 - Teniendo en cuenta las pruebas de comparación múltiple que reporta el manual, realice un programa en SAS para hacer el análisis de esta información.
6. Considere un experimento en BCA con 4 tratamientos, en el cual uno de estos es un control (tratamiento testigo). Se sabe además que el efecto medio de las 32 unidades experimentales es 40, el efecto medio del segundo tratamiento es 42 y el efecto medio del tercer tratamiento es 64. Se conoce además la siguiente tabla de análisis de varianza:

C de V	gl	SC	CM	F
Bloques			32	
Tratamientos			64	
Error experimental			16	
Total	31			

- Presente en forma explícita la matriz diseño.

- b. ¿Cuál es la varianza estimada del error experimental? Interpretelo.
 - c. ¿Cuál es el coeficiente de variación? Interpretelo.
 - d. ¿Cuál es la varianza de una media de tratamiento?
 - e. ¿Es significativa la diferencia entre los tratamientos 2 y 3?
7. En un ensayo con animales, estos fueron bloqueados por peso, en 3 grupos para la composición de tres dietas en el control de la obesidad. El peso final en gramos es el siguiente:

Tratamiento	Bloques					
	1	2	3	4	5	6
1	96	96	94	99	99	102
2	103	101	103	105	101	107
3	103	104	106	108	109	110

- a. Lleve a cabo la prueba de diferencia entre tratamientos.
 - b. Estime la eficiencia relativa del bloqueo.
8. Suponga que en ejercicio 7 se perdieron los datos del tratamiento 1, bloque 5, y del tratamiento 3, bloque 2, obtenga los estimadores de mínimos cuadrados para estos datos y compárelos con los datos observados. ¿Considera que este es un buen método de estimación de datos faltantes? ¿Por qué?
9. Martínez (1981) reporta un estudio de los efectos del origen del polen en el contenido protéico del maíz. Un maíz con índice protéico bajo (origen de la mazorca) se polinizó con índice alto y con otra clase de bajo, las mediciones reportadas son el porcentaje protéico. Se hicieron dos determinaciones del origen de cada mazorca y del polen.

Mazorca	Índice protéico			
	Proteína alta	Proteína baja	Proteína alta	Proteína baja
1	11.44	12.28	11.22	11.00
2	10.12	9.78	9.54	9.42
3	10.59	10.64	9.95	10.08
4	11.55	11.39	10.67	10.87
5	9.40	9.85	10.06	10.21
6	12.29	12.45	12.10	11.89
7	10.88	11.30	11.26	10.83
8	9.57	9.74	9.44	9.61

Haciendo uso del diseño experimental apropiado, lleve a cabo el análisis escribiendo en detalle su conclusión.

10. La evaluación de 7 variedades de frijol, en el municipio de Taminango (Nariño) dio los siguientes resultados:

Material	I	II	III
Línea ICA-22	1.9	3.5	1.9
Línea ICA-23	1.7	3.5	1.8
Línea ICA-24	2.5	2.7	1.8
Diacol-Nima	1.1	2.1	1.3
Diacol-Calima	2.7	2.1	1.7
Diacol-Andino	1.4	1.7	1.5
Diacol-Lima	1.3	2.5	2.4

- Presente el modelo asociado y la matriz diseño.
 - Efectúe al análisis de varianza e interprete.
 - Estime el promedio de cada variedad o línea.
 - Estime la eficiencia del diseño.
 - Haga las comparaciones de interés.
11. En un estudio sobre crecimiento, desarrollo y adaptación de 6 materiales de sorgo a las condiciones de los Llanos Orientales se usó un diseño de bloques completos aleatorizados con 6 genotipos, 3 replicaciones y 5 plantas por replicación. Los datos que se presentan a continuación corresponden a la longitud de la segunda hoja en la 7^a semana de crecimiento.

Genotipo	I		II		III	
IS8577	5.0	5.8	7.4	5.2	2.5	6.4
	4.7	4.1	5.6	5.0	4.9	5.9
	4.7		5.0		3.4	
ICA-Nnataima	4.7	4.3	4.9	5.4	7.3	3.3
	4.0	3.6	4.4	5.6	5.4	3.7
	5.0		4.4		5.4	
156-P5-SERERE 1	3.5	5.0	7.4	7.3	6.4	6.5
	5.1	4.2	6.1	5.9	6.1	5.9
	4.5		5.9		5.4	
Martin A	4.0	3.7	3.6	3.8	4.5	4.6
	3.0	3.5	4.0	3.8	2.9	3.6
	2.5		3.2		3.5	
Sorchica NH301	3.7	4.2	3.2	4.5	4.4	5.2
	3.7	4.0	4.2	5.6	3.8	4.7
	4.1		5.5		4.8	
MN 4508	5.7	5.1	5.1	4.4	6.3	5.7
	6.1	4.5	6.1	5.6	4.6	5.6
	5.2		6.5		3.9	

- a. Haciendo los supuestos necesarios para hacer inferencia, proponga el modelo asociado a este experimento.
- b. Realice la tabla del análisis de varianza e interprete.
- c. Estime los promedios de cada variedad y las componentes de varianza.
- d. Estime la eficiencia del diseño y el coeficiente de variación, e interprételos.
- e. Valide los supuestos del diseño propuesto.
- f. Forme grupos de tratamientos homogéneos.

12. Corra y analice los resultados del siguiente programa en SAS

```
DATA EJEMPLO;
INPUT BLOQUE 1 TRAT 3 Y 5-6;
CARDS;
1 2 14
1 1 76
1 4 15
1 2 35
1 3 62
1 2 56
2 1 62
2 2 91
2 5 48
2 3 24
3 5 31
3 2 12
3 4 93
3 1 62
3 4 81
4 3 42
4 5 45
4 1 78
4 4 29
4 3 27
;
PROC GLM;
CLASS BLOQUE TRAT;
MODEL Y=BLOQUE TRAT;
LSMEANS TRAT;
RUN;
```

13. Se efectuó un experimento en el campo para estimar el efecto de 9 fertilizantes en el rendimiento de avena. En vez de cosechar completamente cada parcela, se tomaron 12 muestras de un metro por un metro en cada parcela, los resultados se resumen en la siguiente tabla:

Causa de variación	gl	SC	CM	Fc
Repeticiones	3			2
Tratamientos				5
Error experimental			192	
Error de muestreo			24	
Total				

- Presente un modelo adecuado para este diseño indicando todos los supuestos necesarios.
- Complete la tabla ANOVA, lleve a cabo la prueba de hipótesis pertinente, obtenga $E(CM)$ y comente su conclusión.
- Si el grupo de fertilizantes es de origen orgánico, presente todos los contrastes de interés y realice una prueba de comparación en cada caso.

14. Suponga el modelo

$$y_{ijk} = \mu + \tau_i + \beta_j + \epsilon_{ij} + \eta_{ijk},$$

con $i = 1, \dots, t$, $j = 1, \dots, b$ y $k = 1, \dots, s$, y donde τ_i es el efecto del i -ésimo tratamiento y β_j es el efecto del j -ésimo bloque.

Teniendo en cuenta los supuestos apropiados, demuestre que:

$$E(SCTra) = bs \sum_{i=1}^t (\tau_i - \bar{\tau})^2 + s(t-1)\sigma_{\epsilon}^2 + (t-1)\sigma_{\eta}^2$$

y obtenga los estimadores para σ_{η}^2 y σ_{ϵ}^2 .

15. Se tiene un diseño en bloques incompletos balanceado tal que $t = 5$, $\lambda = 3$, $k = 3$, $r = 6$ y $b = 10$.

Bloque	Tratamiento			Bloque	Tratamiento		
1	35(1)	28(2)	27(3)	6	25(1)	16(4)	19(5)
2	30(1)	20(2)	22(4)	7	26(2)	30(3)	28(4)
3	28(1)	16(2)	18(5)	8	27(2)	29(3)	27(5)
4	36(1)	29(3)	30(4)	9	29(2)	29(4)	27(5)
5	29(1)	19(3)	22(5)	10	27(3)	26(4)	29(5)

- Encuentre e interprete: la media general del experimento, la estimación de los τ_i , las estimaciones de Q_i y la eficiencia de este diseño.
- Realice el ANOVA y pruebe la(s) hipótesis de interés para este experimento.

- c. Valide los supuestos del diseño propuesto.
- d. Forme grupos de tratamientos homogéneos.
16. Suponga cuatro tratamientos (A, B, C y D), $t = 4, b = 4, k = 3$. Teniendo en cuenta el modelo $y_{ijm} = \mu + \tau_i + \beta_j + \epsilon_{ijm}$, con $i = 1, \dots, 4$, $j = 1, \dots, 4$, y y_{ijm} , la respuesta del i -ésimo tratamiento en el j -ésimo bloque, y según el siguiente arreglo:

B_1	y_{11}	y_{21}	y_{31}	—
B_2	y_{12}	y_{22}	—	y_{42}
B_3	y_{13}	—	y_{33}	y_{43}
B_4	—	y_{24}	y_{34}	y_{44}

realice el ANOVA y proponga la forma de probar la(s) hipótesis de interés para este experimento.

17. Se prueba la resistencia de pegado de seis adhesivos distintos en un proceso de laminación bajo una presión de curado de 200 psi (libras por pulgada cuadrada). Se puede hacer la laminación en bloques de tamaño cuatro. Los resultados obtenidos en este experimento son los siguientes:

Bloque	Resistencia(tratamiento)			
1	24.7(1)	20.8(2)	29.4(3)	24.9(4)
2	24.1(1)	20.4(2)	29.8(3)	30.3(5)
3	23.4(1)	20.6(2)	29.2(3)	34.4(6)
4	23.2(1)	20.7(2)	26.0(4)	30.8(5)
5	21.5(1)	22.1(2)	25.3(4)	35.4(6)
6	21.4(1)	20.1(2)	30.1(5)	34.1(6)
7	23.4(1)	28.7(3)	24.9(4)	31.0(5)
8	23.1(1)	29.3(3)	27.1(4)	34.4(6)
9	22.0(1)	29.8(3)	31.9(5)	36.1(6)
10	22.8(1)	22.6(4)	33.2(5)	34.8(6)
11	21.4(2)	29.6(3)	24.8(4)	31.2(5)
12	21.3(2)	28.9(3)	25.3(4)	35.1(6)
13	21.6(2)	29.5(3)	30.4(5)	33.6(6)
14	20.1(2)	25.1(4)	32.9(5)	33.9(6)
15	30.1(3)	24.0(4)	30.8(5)	36.5(6)

- a. Encuentre e interprete: la media general del experimento, la estimación de los τ_i , las estimaciones de Q_i y la eficiencia de este diseño.
- b. Realice el ANOVA y pruebe la(s) hipótesis de interés para este experimento.

- c. Valide los supuestos del diseño propuesto.
- d. Forme grupos de tratamientos homogéneos.

Diseños en cuadro latino y análisis de covarianza

8.1. Diseño en cuadro latino

El diseño en bloques aleatorios es adecuado cuando una fuente de variabilidad extraña se elimina (control local) para poder comparar un conjunto de medias muestrales asociadas con los tratamientos. Una característica importante de este tipo de diseño es su balance, que se logra asignando el mismo número de observaciones a cada tratamiento dentro de cada bloque. La misma clase de balance puede lograrse en otros tipos de diseño más complicados, en los cuales es conveniente eliminar el efecto de varias fuentes extrañas de variabilidad (dos o más).

El diseño en cuadrado latino (DCL) se usa para eliminar dos fuentes de variabilidad, es decir, permite hacer la formación de bloques sistemática en dos direcciones (en el sentido de las filas y las columnas). Por lo tanto, las filas y las columnas representan en realidad dos restricciones sobre la aleatorización.

De esta forma, se llama cuadro latino a un arreglo experimental obtenido a partir de una matriz cuadrada $t \times t$ en la que aparecen t elementos diferentes dados de tal forma que cada fila y cada columna contenga una sola vez cada uno de los elementos en consideración. Cada una de las t^2 celdas resultantes contiene una de las t letras que corresponde a los tratamientos, cada letra ocurre una y solo una vez en cada fila y columna. Algunos ejemplos de cuadrados latinos son:

$$\begin{bmatrix} A & C & B \\ C & B & A \\ B & A & C \end{bmatrix} \quad \begin{bmatrix} A & B & C & D \\ B & C & D & A \\ C & D & A & B \\ D & A & B & C \end{bmatrix} \quad \begin{bmatrix} A & D & C & B & E \\ B & C & E & A & D \\ E & A & B & D & C \\ C & B & D & E & A \\ D & E & A & C & B \end{bmatrix}.$$

Ejemplo 8.1. *Tres métodos de soldadura para conductores eléctricos se ensayaron, se controlaron con dos fuentes extrañas de variabilidad y tres operarios aplicaron la soldadura y la utilización de tres fundentes para soldar. Si los tres operarios y tres fundentes son considerados, el experimento podría disponerse según el siguiente patrón:*

Fundentes	Operario		
	1	2	3
1	A	B	C
2	B	C	A
3	C	A	B

En este arreglo, cada método de soldadura se aplica una sola vez por cada operario junto con cada fundente, y si existieran efectos sistemáticos debido a diferencias entre

los operarios o entre los fundentes, dichos efectos estarían presentes de igual manera en cada tratamiento, esto es, en cada método de soldadura.

Una de las ventajas del DCL es que al hacer el control local en dos direcciones se tiene un mayor control en la variación, resultando el *CME* más pequeño que cuando se usa DCA o DBCA.

Sin embargo, esta clase de experimento presenta algunas desventajas, como son:

- El número de tratamientos se limita al número de filas y al número de columnas.
- Si $t \geq 10$, no es recomendable el uso de cuadros latinos, pues el número de unidades experimentales se incrementa notablemente a medida que t aumenta.

Ejemplo 8.2. *Algunos casos en que se presentan esta clase de experimentos son:*

- a. 9 individuos con 3 profesiones y años de experiencia diferentes.*
- b. 4 máquinas con capacidad de producción para 4 operarios y 4 períodos de tiempo.*

Para la construcción del DCL, Fisher y Yates (1957) dan las siguientes definiciones:

1. **Cuadro latino estándar:** si la primera fila y la primera columna son ordenadas alfabéticamente, se dice que el cuadrado latino es estándar. Hay muchos cuadros latinos estándar de orden $t \times t$.
2. **Cuadro latino conjugado:** dos cuadros latinos son conjugados si las filas de uno corresponden con las columnas del otro.
3. **Cuadro latino conjugado en sí mismo:** si el arreglo por filas y columnas es el mismo, se dice que el cuadrado latino es conjugado en sí mismo.

Para un DCL 2×2 , hay solamente un cuadro latino estándar

$$\begin{bmatrix} A & B \\ B & A \end{bmatrix}.$$

En un DCL 3×3 , también hay solo un cuadro latino estándar

$$\begin{bmatrix} A & B & C \\ B & C & A \\ C & A & B \end{bmatrix},$$

pero hay doce posibles formas de arreglar un cuadro latino 3×3 , las cuales se presentan a continuación:

$$\begin{array}{cccc}
 \begin{bmatrix} A & B & C \\ B & C & A \\ C & A & B \end{bmatrix} & \begin{bmatrix} A & B & C \\ C & A & B \\ B & C & A \end{bmatrix} & \begin{bmatrix} A & C & B \\ B & A & C \\ C & B & A \end{bmatrix} & \begin{bmatrix} A & C & B \\ C & B & A \\ B & A & C \end{bmatrix} \\
 \\
 \begin{bmatrix} B & A & C \\ C & B & A \\ A & C & B \end{bmatrix} & \begin{bmatrix} B & A & C \\ A & C & B \\ C & B & A \end{bmatrix} & \begin{bmatrix} C & B & A \\ A & C & B \\ B & A & C \end{bmatrix} & \begin{bmatrix} C & B & A \\ B & A & C \\ A & C & B \end{bmatrix} \\
 \\
 \begin{bmatrix} B & C & A \\ C & A & B \\ A & B & C \end{bmatrix} & \begin{bmatrix} B & C & A \\ A & B & C \\ C & A & B \end{bmatrix} & \begin{bmatrix} C & A & B \\ A & B & C \\ B & C & A \end{bmatrix} & \begin{bmatrix} C & A & B \\ B & C & A \\ A & B & C \end{bmatrix} .
 \end{array}$$

Para un cuadro latino de orden t , el número total de cuadros es obtenido al multiplicar el número de cuadros latinos estándares por $t!(t-1)!$. En la tabla 8.1, se resumen algunos de los resultados anteriores acerca de los cuadrados latinos estándares y no estándares.

Tabla 8.1: Cuadrados latinos estándares y número de cuadrados latinos

Tamaño	No. CL estándares	No. total de CL
2×2	1	2
3×3	1	12
4×4	4	576
5×5	56	161280
6×6	9408	818851200
7×7	169212080	61479419904000
$\vdots$	$\vdots$	$\vdots$
$t \times t$	-	$t!(t-1)!$ (No CL estándares)

El modelo estadístico para un diseño en cuadrado latino (DCL) es el siguiente:

$$y_{ijk} = \mu + \beta_i + \gamma_j + \tau_k + \epsilon_{ijk}, \quad i, j, k = 1, \dots, t, \quad (8.1)$$

donde y_{ijk} es la observación en la fila i -ésima y la columna j -ésima para el tratamiento k -ésimo, μ es la media global, β_i es el efecto de la fila i -ésima, γ_j el efecto de la columna j -ésima, τ_k el efecto del tratamiento k -ésimo y ϵ_{ijk} es el error aleatorio.

El conjunto de ecuaciones normales obtenidas con el procedimiento de estimación de mínimos cuadrados es

$$\begin{aligned} t^2 \hat{\mu} + t \left(\sum_{i=1}^t \hat{\beta}_i + \sum_{j=1}^t \hat{\gamma}_j + \sum_{k=1}^t \hat{\tau}_k \right) &= y_{...} \\ t \hat{\mu} + t \hat{\beta}_i + \sum_{j=1}^t \hat{\gamma}_j + \sum_{k=1}^t \hat{\tau}_k &= y_{i..} \\ t \hat{\mu} + \sum_{i=1}^t \hat{\beta}_i + t \hat{\gamma}_j + \sum_{k=1}^t \hat{\tau}_k &= y_{.j.} \\ t \hat{\mu} + \sum_{i=1}^t \hat{\beta}_i + \sum_{j=1}^t \hat{\gamma}_j + t \hat{\tau}_k &= y_{..k}. \end{aligned}$$

Bajo las restricciones de no estimabilidad, $\sum_{i=1}^t \beta_i = \sum_{j=1}^t \gamma_j = \sum_{k=1}^t \tau_k = 0$, se encuentra las siguientes estimaciones de los parámetros

$$\hat{\mu} = \bar{y}_{...}, \quad \hat{\beta}_i = \bar{y}_{i..} - \bar{y}_{...}, \quad \hat{\gamma}_j = \bar{y}_{.j.} - \bar{y}_{...} \quad \text{y} \quad \hat{\tau}_k = \bar{y}_{..k} - \bar{y}_{...}.$$

Dado que los efectos de filas, columnas y tratamientos son ortogonales se puede entonces evaluar la contribución de cada una de sus componentes a la suma de cuadrados total, es decir,

$$SCT_{CM} = SCFilas + SCColum + SCTrata + SCE$$

con los respectivos grados de libertad, $t^2 - 1 = t - 1 + t - 1 + t - 1 + (t - 2)(t - 1)$, y las respectivas sumas de cuadrados

$$\begin{aligned} SCT_{CM} &= \sum_{ijk} y_{ijk}^2 - \frac{y_{...}^2}{t^2} \\ SCTrata &= \sum_k \frac{y_{..k}^2}{t} - \frac{y_{...}^2}{t^2} \\ SCFilas &= \sum_i \frac{y_{i..}^2}{t} - \frac{y_{...}^2}{t^2} \\ SCColum &= \sum_j \frac{y_{.j.}^2}{t} - \frac{y_{...}^2}{t^2}. \end{aligned}$$

La suma de cuadrados del error se obtiene por diferencia, es decir

$$SCE = SCT_{CM} - SCFilas - SCColum - SCTrata.$$

El estadístico apropiado para probar que no hay diferencias entre las medias de los tratamientos ($H_0 : \tau_1 = \tau_2 = \cdots = \tau_t$) es

$$F = \frac{\frac{SCTrata}{t-1}}{\frac{SCE}{(t-1)(t-2)}},$$

el cual bajo H_0 cierta se distribuye como $F_{((t-1), (t-1)(t-2))}$. También puede plantearse la hipótesis para evaluar la ausencia de efectos de las filas o columnas formando el cociente de $CMFilas$ o $CMColum$ con CME . Sin embargo, puesto que las filas y las columnas representan restricciones sobre la aleatorización, estas pruebas no son apropiadas.

Los resultados anteriores, se resumen en la tabla ANOVA 8.2 para un DCL.

Tabla 8.2: Análisis de varianza del DCL

C de V	gl	SC	CM	E(CM)	F
Filas	$t - 1$	$SCFilas$	$CMFilas$	$\sigma^2 + \sum_i \phi(F)_i^2$	$\frac{CMTrata}{CME}$
Colum	$t - 1$	$SCColum$	$CMColum$	$\sigma^2 + \sum_j \phi(C)_j^2$	
Trata	$t - 1$	$SCTrata$	$CMTrata$	$\sigma^2 + \sum_k \phi(T)_k^2$	
Error	$(t - 1)(t - 2)$	SCE	CME	σ^2	
Total	$t^2 - 1$	SCT_{CM}			

Ejemplo 8.3. En Kenett y Zacks (2000) se presenta un experimento, en que se probaron cuatro métodos distintos, A, B, C y D, para preparar mezclas de concreto. Consistieron los métodos de dos relaciones de cemento y agua, y dos duraciones de mezclado. Los cuatro métodos fueron controlados por cuatro lotes durante cuatro días. El concreto se coló en cilindros y se midió la resistencia a la compresión en kg/cm^2 , a los 7 días de almacenamiento en cámaras especiales con 20°C de temperatura y 50 % de humedad relativa. Los resultados del diseño que se uso se presentan en la tabla 8.3.

Tabla 8.3: Datos sobre resistencia del concreto a la compresión en kg/cm^2

Días	Lotes			
	1	2	3	4
1	A	B	C	D
	303	299	290	290
2	B	A	D	C
	280	321	313	282
3	C	D	A	B
	275	315	319	300
4	D	C	B	A
	304	293	295	305

Las sumas de cuadrados asociadas a cada fuente de variación son las siguientes:

$$\begin{aligned}
 SCT_{CM} &= 1433270 - \frac{4784^2}{16} = 2854 \\
 SC_{Metodo} &= \frac{1}{4}(1248^2 + 1174^2 + 1140^2 + 1222^2) - \frac{4784^2}{16} = 1750 \\
 SC_{Dias} &= \frac{1}{4}(1182^2 + 1196^2 + 1209^2 + 1197^2) - \frac{4784^2}{16} = 91.5 \\
 SC_{Lote} &= \frac{1}{4}(1162^2 + 1228^2 + 1217^2 + 1177^2) - \frac{4784^2}{16} = 745.5.
 \end{aligned}$$

y, por diferencia,

$$SCE = SCT_{CM} - SC_{Metodo} - SC_{Dias} - SC_{Lote} = 267.$$

Los anteriores resultados se resumen en la tabla 8.4. A partir de esta, con un nivel de significación del 5% el valor F es $F_{(3,6,0.05)} = 4.757$ y puesto que $F_c = 13.11$, se concluye que el método afecta la resistencia a la compresión. Además, al parecer los días no difieren significativamente en dicha resistencia (el cuadrado medio es pequeño en relación con el cuadrado medio del error), mientras los lotes sí, puesto que el cuadrado medio es grande en relación con el error.

Tabla 8.4: Análisis de varianza para la resistencia a la compresión en kg/cm^2

C. de V.	g.l.	SC	CM	F	Valor p
Día	3	91.5	30.5		
Lote	3	745.5	248.5		
Método	3	1750.0	583.3	13.11	0.00
Error	6	267.0	44.5		
Total	15	2854.0			

8.1.1. Estimación de un dato faltante en un DCL

Cuando hay pocos datos perdidos con este diseño, se recomienda hacer una estimación de estas para así mantener la ortogonalidad en el diseño. Suponga que se perdió la unidad experimental en la fila u , columna v , tratamiento w .

Si R_u , C_v , T_w son los totales con información completa respectivamente para las filas, columnas y tratamientos donde está el dato faltante, por ejemplo x , y G es el gran total con la información completa, entonces para estimar la información faltante se parte de la suma de cuadrados del ANOVA de la tabla 8.5.

Tabla 8.5: Análisis de varianza para estimar un dato faltante

C de V	SC
Filas	$\frac{1}{t}(R_u + x)^2 + \frac{1}{t} \sum_{\substack{i=1 \\ i \neq u}}^t y_{i..}^2 - \frac{(G+x)^2}{t^2}$
Columnas	$\frac{1}{t}(C_v + x)^2 + \frac{1}{t} \sum_{\substack{j=1 \\ j \neq v}}^t y_{.j}^2 - \frac{(G+x)^2}{t^2}$
Tratamientos	$\frac{1}{t}(T_w + x)^2 + \frac{1}{t} \sum_{\substack{k=1 \\ k \neq w}}^t y_{..k}^2 - \frac{(G+x)^2}{t^2}$
Error	Diferencia
Total	$x^2 + \sum_{\substack{i=1 \\ i \neq u}}^t \sum_{\substack{j=1 \\ j \neq v}}^t \sum_{\substack{k=1 \\ k \neq w}}^t y_{ijk}^2 - \frac{(G+x)^2}{t^2}$

A partir la *SCE*, se evidencia que minimizar dicha suma con respecto a x es equivalente a minimizar

$$Q = x^2 + 2 \frac{(G+x)^2}{t^2} - \frac{1}{t}(R_u + x)^2 - \frac{1}{t}(C_v + x)^2 - \frac{1}{t}(T_w + x)^2.$$

Luego, derivando Q con respecto a x , se obtiene

$$\frac{dQ}{dx} = 2x + 4 \frac{(G+x)}{t^2} - \frac{2}{t}(R_u + x) - \frac{2}{t}(C_v + x) - \frac{2}{t}(T_w + x) = 0.$$

Como resultado se obtiene como estimador del dato faltante la expresión

$$\hat{x} = \frac{t(R_u + C_v + T_w) - 2G}{(t-1)(t-2)}. \quad (8.2)$$

Ejemplo 8.4. Suponga que para la información obtenida en el ejemplo 8.3 se perdió el dato correspondiente al día 3, lote 2 y método D, utilizando la ecuación 8.2, se encuentra:

$$\hat{x} = \frac{4(894 + 913 + 907) - 2(4469)}{(3)(2)} = 319.67.$$

Este valor estimado está muy cerca del verdadero valor observado, 315.

8.1.2. Eficiencia de un DCL frente a un DCA y un DBCA

En muchas circunstancias experimentales, el investigador desea estimar la eficiencia del uso de un DCL frente a un DCA o a un DBCA, así los tratamientos hubiesen sido completamente aleatorizados en todas las UE. Un método para obtener esta eficiencia consiste en comparar algebraicamente lo que podría haber pasado al CME_{DCL} bajo aleatorización completa.

Recordando que

$$CME_{DCL} = \frac{SCE_{DCL}}{(t-2)(t-1)}.$$

En primer lugar se compara el DCL con el DCA. Para este fin, se observa que el cuadrado medio del error de un DCA en términos de un DCL, está dado por:

$$\begin{aligned} CME_{DCA} &= \frac{(t-1)CMFila + (t-1)CMColum + (t-2)(t-1)CME_{DCL}}{(t-1) + (t-1) + (t-2)(t-1)} \\ &= \frac{CMFila + CMColum + (t-2)CME_{DCL}}{t}. \end{aligned}$$

Por consiguiente, la eficiencia relativa (ER) del DCA con respecto al DCL es

$$\begin{aligned} ER_{DCA \rightarrow DCL} &= \frac{CMFila + CMColum + (t-2)CME_{DCL}}{tCME_{DCL}} \\ &= \frac{CMFila}{tCME_{DCL}} + \frac{CMColum}{tCME_{DCL}} + \left(1 - \frac{2}{t}\right) \\ &= 1 - \frac{1}{t}(1 - F_F) - \frac{1}{t}(1 - F_C), \end{aligned}$$

donde $F_F = \frac{CMFila_{DCL}}{CME_{DCL}}$ y $F_C = \frac{CMColum_{DCL}}{CME_{DCL}}$. Ahora, si F_F y F_C son mayores de 1, entonces $ER_{DCA \rightarrow DCL} > 1$, siendo más eficiente el DCL que el DCA.

En segundo lugar se compara el DCL con el DBCA. En este caso, al igual que en la situación anterior, el cuadrado medio del error de un DBCA se puede expresar en términos de un DCL como:

$$\begin{aligned} CME_{DBCA} &= \frac{(t-1)CMFila + (t-2)(t-1)CME_{DCL}}{(t-1) + (t-2)(t-1)} \\ &= \frac{CMFila + (t-2)CME_{DCL}}{t-1}. \end{aligned}$$

Por lo tanto, la ER del DBCA con respecto al DCL es:

$$\begin{aligned} ER_{DBCA \rightarrow DCL} &= \frac{CMFila + (t-2)CME_{DCL}}{(t-1)CME_{DCL}} \\ &= 1 - \frac{1}{t-1}(1 - F_F). \end{aligned}$$

Si en la expresión anterior $F_F > 1$, entonces $ER > 1$, y resulta ser más eficiente el DCL; en caso contrario, lo sería el DBCA.

Ejemplo 8.5. Con base en los datos del ejemplo 8.3, se evalúa la eficiencia del DCA y el DBCA con respecto al DCL para saber si realmente el DCL está reduciendo el ruido en los datos para que las diferencias entre los cuatro métodos sean detectadas. Entonces,

$$\begin{aligned} ER_{DCA \rightarrow DCL} &= \frac{CMDias + CMLotes + (t - 2)CME_{DCL}}{tCME_{DCL}} \\ &= 1 - \frac{1}{t}(1 - F_D) - \frac{1}{t}(1 - F_L) \\ &= 1 - \frac{1}{4}(1 - 0.685) - \frac{1}{4}(1 - 5.584) = 2.067. \end{aligned}$$

Como $ER_{DCA \rightarrow DCL} > 1$ es más eficiente el DCL que el DCA.

Análogamente, al comparar el DBCA con el DCL se encuentra que

$$\begin{aligned} ER_{DBCA \rightarrow DCL} &= \frac{CMDias + (t - 2)CME_{DCL}}{(t - 1)CME_{DCL}} = 1 - \frac{1}{t - 1}(1 - F_D) \\ &= 1 - \frac{1}{3}(1 - 0.685) = 0.895. \end{aligned}$$

Con lo cual el día no es un factor de control importante en este experimento; esto puede sugerir que a futuro es más eficiente realizar un DBCA.

8.2. Series de cuadros latinos

Si t es pequeño, entonces se hace necesario aumentar los grados de libertad para poder estimar el EE. Una forma de ganar grados de libertad es construir más cuadros latinos, generándose así series de cuadrados latinos, en los cuales posteriormente se hace la distribución de los tratamientos dentro de cada cuadro. Si, por ejemplo, se tiene un DCL 4×4 , una disposición de los tratamientos sería:

$$\begin{array}{ccccccccc} 1 & 4 & 2 & 3 & \vdots & 3 & 2 & 4 & 1 \\ 3 & 2 & 1 & 4 & \vdots & 1 & 4 & 3 & 2 \\ 2 & 3 & 4 & 1 & \vdots & 2 & 3 & 1 & 4 \\ 4 & 1 & 3 & 2 & \vdots & 4 & 1 & 2 & 3. \end{array}$$


El análisis estadístico en este caso se hace obteniendo los totales por filas y columnas dentro de cada cuadro, los totales por cuadro, los totales por tratamiento sobre todos los cuadros y el gran total.

El modelo lineal para series de cuadrados latinos es:

$$y_{ijkl} = \mu + q_i + \beta_{j(i)} + \gamma_{k(i)} + \tau_l + \epsilon_{ijkl}, \quad (8.3)$$

con $i = 1, \dots, q$ y $j, k, l = 1, \dots, t$.

Al modelo (8.3) se le asocia el siguiente diagrama de estructura:



A partir del anterior diagrama de estructuras se obtienen las diferentes sumas de cuadrados asociadas al modelo (8.3), las cuales, según lo presentado en el capítulo 4, son:

$$SCT_{CM} = \sum_{ijkl} y_{ijkl}^2 - \frac{y_{\dots}^2}{qt^2}$$

$$SCQ = \sum_{i=1}^q \frac{y_{i\dots}^2}{t^2} - \frac{y_{\dots}^2}{qt^2}$$

$$SC(F : Q) = \sum_{i=1}^q \sum_{j=1}^t \frac{y_{ij\dots}^2}{t} - \sum_{i=1}^q \frac{y_{i\dots}^2}{t^2}$$

$$SC(C : Q) = \sum_{i=1}^q \sum_{k=1}^t \frac{y_{i.k\dots}^2}{t} - \sum_{i=1}^q \frac{y_{i\dots}^2}{t^2}$$

$$SCTr_{ata} = \sum_{l=1}^t \frac{y_{\dots l}^2}{qt} - \frac{y_{\dots}^2}{qt^2}$$

$$SCE = SCT_{CM} - SCQ - SC(F : Q) - SC(C : Q) - SCTr_{ata}.$$

Con estas sumas de cuadrados se encuentra la ANOVA para los q cuadros, la cual se resume en la tabla 8.6.

Tabla 8.6: Análisis de varianza para una serie de cuadrados latinos

C de V	g.l.	SC	CM	F
Cuadros	$q - 1$	SCQ	CMQ	
Filas:cuadros	$q(t - 1)$	$SC(F : Q)$	$CM(F : Q)$	
Colum:cuadros	$q(t - 1)$	$SC(C : Q)$	$CM(C : Q)$	
Tratamientos	$t - 1$	$SCTrata$	$CMTrata$	$\frac{CMTrata}{CME}$
Error	$q(t - 1)^2 - (t - 1)$	SCE	CME	
Total	$qt^2 - 1$	SCT_{CM}		

A partir de los resultados obtenidos en la tabla 8.6, se puede contrastar la hipótesis $H_0 : \tau_1 = \dots = \tau_t$, la cual se rechaza si

$$F = \frac{CMTrata}{CME} > F_{(t-1, q(t-1)^2 - (t-1), \alpha)}.$$

El estimador de un contraste entre efectos de tratamientos, por ejemplo, la combinación lineal $\sum_{l=1}^t \lambda_l \tau_l$, es dado por el mismo contraste de las medias de tratamientos, $\sum_{l=1}^t \lambda_l \bar{y}_{...l}$. Se tiene además que:

$$Var \left(\sum_{l=1}^t \lambda_l \bar{y}_{...l} \right) = \frac{\sigma^2}{qt} \sum_{l=1}^t \lambda_l^2$$

y, por consiguiente, un intervalo de confianza del $(1 - \alpha) \%$ está dado por:

$$\sum_{l=1}^t \lambda_l \bar{y}_{...l} \mp t_{(q(t-1)^2 - (t-1), \alpha/2)} \sqrt{\frac{CME}{qt} \sum_{l=1}^t \lambda_l^2}.$$

Ejemplo 8.6. Suponga que se tiene un ensayo en que se desean comparar dos raciones (A y B) durante dos períodos en un grupo de vacas lecheras:

Vacas	1	2	3	4	5	6	7	8	9	10
Período 1	B	A	B	A	A	B	B	A	A	B
Período 2	A	B	A	B	B	A	A	B	B	A

La tabla de ANOVA asociada al modelo

$$y_{ijk} = \mu + P_i + T_j + V_k + e_{ijk},$$

con $i = 1, 2$, $j = 1, 2$ y $k = 1, \dots, 10$, es:

C de V	g.l.
Vacas	9
Períodos	1
Tratamientos	1
Error	8
Total	19

Si se hace un arreglo de una serie de cuadros latinos, se tienen 5 series de cuadros latinos según el siguiente arreglo:

Cuadros	I		II		III		IV		V	
Vacas	1	2	3	4	5	6	7	8	9	10
Período 1	B	A	B	A	A	B	B	A	A	B
Período 2	A	B	A	B	B	A	A	B	B	A

El modelo lineal para este caso es:

$$y_{ijkl} = \mu + Q_i + V_{j(i)} + P_{k(i)} + T_l + \epsilon_{ijkl}$$

con $i = 1, \dots, q$ y $j, k, l = 1, \dots, t$. Por lo tanto, la tabla para este arreglo de cuadros es:

C de V	g.l.
Cuadros	4
Vacas dentro de cuadros	5
Períodos dentro de cuadros	5
Tratamientos	1
Error	4
Total	19

Ejemplo 8.7. Considere dos cuadrados latinos de 4×4 , en los que se midió el peso en libras de 100 manzanas compradas por los clientes. El cuadrado latino 1 corresponde al experimento realizado en la primera semana y el cuadrado latino 2 al experimento realizado en la segunda semana. Las filas son los 4 primeros días de la semana y las columnas 4 supermecados de cadena de la ciudad. Los tratamientos utilizados fueron: A (manzana regular al precio menor), B (manzana calidad media), C (manzana uniforme) y D (manzana uniforme de color blanco). Los datos del experimento se presentan en la tabla 8.7.

Tabla 8.7: Pesos en libras de 100 manzanas en dos cuadrados latinos replicados 4×4

Día	Semana 1				Semana 2			
	Supermercado				Supermercado			
	1	2	3	4	1	2	3	4
Lunes	A	B	C	D	B	D	C	A
	14	8	40	48	24	30	24	12
Martes	B	A	D	C	D	A	B	C
	20	22	48	25	42	4	12	32
Miércoles	D	C	B	A	A	C	D	B
	24	12	12	27	8	8	36	28
Jueves	C	D	A	B	C	B	A	D
	31	16	32	22	28	32	48	54

Por otro lado, también se puede considerar el modelo lineal

$$y_{ijkl} = \mu + W_i + D_{j(i)} + S_{k(i)} + T_l + e_{ijkl}, \quad (8.4)$$

en el que $i = 1, 2$ y $j, k, l = 1, 2, 3, 4$. Al imponer las restricciones apropiadas sobre cada uno de los términos y sobre el error, se obtiene las siguientes sumas de cuadrados asociadas con cada fuente de variación:

$$SCT_{CM} = 26675 - \frac{823^2}{32} = 5508.4$$

$$SCW = \frac{1}{16}(401^2 + 422^2) - \frac{823^2}{32} = 13.8$$

$$SC(D : W) = \frac{1}{4}(110^2 + \dots + 162^2) - \frac{401^2 + 422^2}{16} = 1318.4$$

$$SC(S : W) = \frac{1}{4}(89^2 + \dots + 126^2) - \frac{401^2 + 422^2}{16} = 1256.9$$

$$SCTr = \frac{167^2 + 158^2 + 200^2 + 298^2}{8} - \frac{823^2}{32} = 1540.6,$$

y, por diferencia,

$$SCE = SCT_{CM} - SCW - SC(D : W) - SC(S : W) - SCTr = 1378.72.$$

Los anteriores resultados se resumen en la tabla 8.8. A partir de la misma, con un nivel de significación del 5% el valor F es $F_{(3,15,0.05)} = 4.757$ y, puesto que $F_c = 5.59$, se rechaza la hipótesis nula $H_0 : T_1 = T_2 = T_3 = T_4$ (valor $p = 0.009$). Además, los días dentro de semanas aunque parecen no ser tan importantes ($F = 2.39$) al igual que los supermercados dentro de semanas ($F = 2.28$), sus valores en el estadístico $F > 1$ son dos buenas fuentes de control local. Sin embargo, las semanas no fueron un factor importante ($F = 0.15$).

Tabla 8.8: Análisis de varianza para los pesos en libras de 100 manzanas usando series de cuadrados latinos.

C. de V.	g.l.	SC	CM	F	Valor p
Semanas	1	13.78	13.78	0.15	
Días (semanas)	6	1318.44	219.74	2.39	
Supermercados (semanas)	6	1256.94	209.49	2.28	
Tratamientos	3	1540.59	513.53	5.59	0.009
Error	15	1378.72	91.91		
Total	31	5508.4			

Por otro lado, también se puede considerar el modelo lineal

$$y_{ijk} = \mu + S_i + D_j + T_k + e_{ijk}, \quad (8.5)$$

donde $i = 1, \dots, 8$ y $j, k = 1, 2, 3, 4$. Al imponer las restricciones apropiadas sobre cada uno de los términos y sobre el error, se obtiene la tabla 8.9 de análisis de varianza. De acuerdo con estos resultados, se rechaza la hipótesis nula $H_0 : T_1 = T_2 = T_3 = T_4$ al nivel de significación del 5 % (valor $p = 0.013$). Además, los días aunque parecen no ser tan importantes ($F = 2.25$) al igual que los supermercados ($F = 1.67$), sus valores en el estadístico $F > 1$ son dos buenas fuentes de control local.

Tabla 8.9: Análisis de varianza para los pesos en libras de 100 manzanas usando el diseño de la ecuación (8.5)

C de V	g.l.	SC	CM	F	valor p
Supermercados	7	1270.72	181.53	1.67	
Días	3	735.84	245.28	2.25	
Tratamientos	3	1540.59	513.53	4.71	0.013
Error	18	1961.31	108.96		
Total	31	5508.4			

8.3. Diseño en Cuadrado Greco-Latino

Al usar el cuadrado latino es posible remover dos fuentes de variación del error experimental mediante el uso de clasificaciones en filas y columnas de las unidades experimentales. Se puede avanzar otra etapa y controlar una nueva fuente de variación usando el Diseño en Cuadrado Greco-Latino (DCGL).

Considérense dos cuadros latinos de 4×4 ,

$$\begin{bmatrix} A & B & C & D \\ B & A & D & C \\ C & D & A & B \\ D & C & B & A \end{bmatrix} \quad \begin{bmatrix} \alpha & \beta & \gamma & \delta \\ \gamma & \delta & \alpha & \beta \\ \delta & \gamma & \beta & \alpha \\ \beta & \alpha & \delta & \gamma \end{bmatrix}.$$

Al superponer estos dos cuadros, se tiene un arreglo en DCGL como el que se presenta en la tabla 8.10.

Tabla 8.10: Arreglo de tratamientos en un Diseño en Cuadro Greco-Latino 4×4

Fila	Columna			
	1	2	3	4
1	$A\alpha$	$B\beta$	$C\gamma$	$D\delta$
2	$B\gamma$	$A\delta$	$D\alpha$	$C\beta$
3	$C\delta$	$D\gamma$	$A\beta$	$B\alpha$
4	$D\beta$	$C\alpha$	$B\delta$	$A\gamma$

Se puede verificar que cada elemento del primer cuadro latino (A , por ejemplo) ocurre junto con cada uno de los elementos del segundo ($\alpha, \beta, \gamma, \delta$) y, recíprocamente, cada elemento de la segunda matriz (β , por ejemplo) ocurre con cada uno de los elementos del primero (A, B, C, D). Aquellos cuadros latinos que cumplen esta propiedad se conocen como diseños en cuadros *ortogonales* o también son llamados DCGL.

Surgen luego algunas preguntas:

- ¿Cuántos cuadros latinos ortogonales existen para cada caso?
- ¿Cómo se pueden obtener estos cuadros latinos?

En el DCGL, las unidades experimentales se agrupan en tres formas diferentes; así como sucedió con el DCL, un diseño de t tratamientos necesita t^2 unidades experimentales. Estas se agrupan en filas y columnas, y mediante una clasificación adicional que se designa con letras griegas. La asignación o distribución de las letras griegas está restringida de forma tal que cada letra griega debe ir una vez y solo una vez en cada fila y en cada columna. Así, las letras griegas forman un cuadro latino con respecto a filas y columnas. Los tratamientos designados mediante letras latinas ahora se asignan a las unidades experimentales de manera tal que cada tratamiento ocurre una sola vez en cada fila, en cada columna y en cada letra griega.

La principal ventaja es que permite controlar la variabilidad de tres fuentes de variación (control en la aleatorización). Mientras, una desventaja de este diseño es que la pérdida de datos complica a menudo el análisis.

Observación 8.1. Se pueden construir cuadrados grecolatinos para todo número de tratamientos mayores o iguales a 3, excepto para 6. Teóricamente, es posible utilizar estos diseños para cualquier t , siempre y cuando t sea un número primo o la potencia de un número primo.

El modelo estadístico para este diseño es:

$$y_{ijkl} = \mu + \beta_i + \gamma_j + \tau_k + \psi_l + \epsilon_{ijkl}, \quad i, j, k, l = 1, \dots, t, \quad (8.6)$$

donde y_{ijkl} es la observación en la fila i -ésima, la columna j -ésima, la letra latina k -ésima y la letra griega l -ésima, μ es la media global, β_i es el efecto de la fila i -ésima, γ_j el efecto de la columna j -ésima, τ_k el efecto del tratamiento de la letra latina k -ésima, ψ_l el efecto del tratamiento de la letra griega l -ésima y ϵ_{ijkl} es el error aleatorio.

El análisis estadístico es muy similar al del DCL. Por lo tanto, puede calcularse una suma de cuadrados debida al factor de las letras griegas a partir de los totales de las letras griegas y el error experimental se reduce adicionalmente en esta cantidad. En la tabla 8.11, se ilustra el ANOVA asociado con el

modelo (8.6). La hipótesis nula de igualdad de tratamientos, de letras latinas y griegas se realiza dividiendo el cuadrado medio correspondiente por el cuadrado medio del error. Este valor se compara con una $F_{(t-1, (t-3)(t-1), \alpha)}$.

Tabla 8.11: Análisis de varianza para un DCGL

C de V	gl	SC
Filas	$t - 1$	$\frac{1}{t} \sum_{i=1}^t y_{i...}^2 - \frac{y_{...}^2}{t^2}$
Colum	$t - 1$	$\frac{1}{t} \sum_{j=1}^t y_{.j..}^2 - \frac{y_{...}^2}{t^2}$
Trata latinas	$t - 1$	$\frac{1}{t} \sum_{k=1}^t y_{...k.}^2 - \frac{y_{...}^2}{t^2}$
Trata griegas	$t - 1$	$\frac{1}{t} \sum_{l=1}^t y_{...l}^2 - \frac{y_{...}^2}{t^2}$
Error	$(t - 3)(t - 1)$	Diferencia
Total	$t^2 - 1$	$\sum_{ijkl} y_{ijkl}^2 - \frac{y_{...}^2}{t^2}$

También puede probarse la ausencia de efectos de las filas o columnas formando el cociente de CM_{Filas} o CM_{Colum} , respectivamente, con CME . Sin embargo, al igual que en DCL, puesto que las filas y las columnas representan restricciones sobre la aleatorización, estas pruebas no son apropiadas.

Ejemplo 8.8. *Suponga que en el experimento de la resistencia del concreto a la compresión del ejemplo 8.3 la máquina con que se prepara el mismo podría ser importante. Las cuatro máquinas de prueba se denotan por las letras griegas α , β , γ y δ , como se ilustra en la tabla 8.12, del arreglo respectivo.*

Tabla 8.12: DCGL para el problema de la resistencia del concreto a la compresión

Días	Lotes			
	1	2	3	4
	$A\alpha$	$B\beta$	$C\gamma$	$D\delta$
1	303	299	290	290
	$B\delta$	$A\gamma$	$D\beta$	$C\alpha$
2	280	321	313	282
	$C\beta$	$D\alpha$	$A\delta$	$B\gamma$
3	275	315	319	300
	$D\gamma$	$C\delta$	$B\alpha$	$A\beta$
4	304	293	295	305

Debido a que los totales de días (filas), los lotes (columnas) y los métodos (letras latinas) son idénticos a los del ejemplo 8.3, se debe solamente obtener las sumas de cuadrados debida a las máquinas. Esta es:

$$\begin{aligned}
 SCMáquina &= \frac{1}{t} \sum_{l=1}^t y_{...l}^2 - \frac{y_{....}^2}{t^2} \\
 &= \frac{1}{4} (1195^2 + 1192^2 + 1215^2 + 1182^2) - \frac{4784^2}{16} = 143.5.
 \end{aligned}$$

En la tabla 8.13, se resume el análisis de varianza completo. A partir del mismo, se encuentra que los métodos difieren ($F_m = 14.17 > F_{(3,3,0.05)} = 9.277$). Además, al parecer los días y las máquinas no difieren significativamente en dicha resistencia (el cuadrado medio es pequeño en relación con el del error), mientras los lotes sí.

Al comparar las tablas 8.4 y 8.13, se observa que al sacar la variabilidad debida a las máquinas el error experimental disminuye. Sin embargo, al disminuir el error experimental, se han reducido también los grados de libertad de 6 (en el DCL del ejemplo 8.3) a 3. Por lo tanto, la estimación del error tiene menos grados de libertad y la prueba es menos sensible.

Tabla 8.13: Análisis de varianza para la resistencia a la compresión a través de DCGL

C. de V.	g.l.	SC	CM	F	Valor p
Día	3	91.5	30.50		
Lote	3	745.5	248.50		
Máquina	3	143.5	47.83		
Método	3	1750.0	583.30	14.17	0.03
Error	3	123.5	41.16		
Total	15	2854.0			

Puede hacerse cierta ampliación del concepto de un cuadrado grecolatino; un *hipercuadrado* $t \times t$ es un diseño en el que superponen tres o más cuadrados latinos ortogonales $t \times t$. En general, hasta $t + 1$ factores podrían estudiarse si se dispone de un conjunto de $t - 1$ cuadrados latinos ortogonales. En este diseño se utilizan todos los $(t + 1)(t - 1) = t^2 - 1$ grados de libertad, por lo que se necesita una estimación independiente de la varianza del error. Desde luego, no deben existir las interacciones entre los factores cuando se usan hipercuadrados.

8.4. Análisis de covarianza

Cuando en experimentación, simultáneamente con los valores de las características en estudio (factores), se observa sobre cada UE los valores de una o más variables fijas cuya medida se realiza sin error, las cuales tienen efecto sobre características de interés, se logra una reducción del EE con el uso de

estas variables auxiliares en el modelo. A este método de reducción se le conoce como *análisis de covarianza*. Este método es otro de los tantos que se recomienda en el análisis de varianza para reducir el EE. Como se ha dicho en los capítulos anteriores, los métodos experimentales se basan en:

- a. La selección de un material homogéneo, i. e., realizar el experimento en un medio ambiente homogéneo.
- b. Estratificar el medio ambiente en grupos homogéneos, llamados normalmente bloques.
- c. El refinamiento de la técnica experimental.

En particular, este análisis de reducción se recomienda cuando la variación experimental no puede ser controlada totalmente por la estratificación (bloqueo). Para reducir EE se introducen unas variables concomitantes o covariables, las cuales se deben usar cuidadosamente.

Como ejemplos del uso de covariables se menciona:

- a. Efecto de raciones sobre la ganancia de peso. En este caso, una covariable es el peso inicial del animal.
- b. Rendimiento en cultivos. La covariable es la densidad de las plantas.
- c. Comparación de varios métodos de enseñanza. La covariable es el coeficiente intelectual (QI).

En la selección de variables concomitantes debe tenerse la precaución de que no sean afectadas por los tratamientos; si hubiese algún efecto entonces se debe ser cuidadoso en la interpretación.

Un ejemplo del caso anterior sería usar la cantidad de alimento que se consume en vez del peso inicial, es posible que los tratamientos tengan un efecto significativo en el consumo.

A continuación se presentan algunos modelos con covariables:

- a. En un DCA

$$y_{ij} = \mu_0 + \tau_i + \beta x_{ij} + \epsilon_{ij} \quad \text{ó} \quad y_{ij} = \mu + \tau_i + \beta(x_{ij} - \bar{x}_{..}) + \epsilon_{ij},$$

para $i = 1, \dots, t$, $j = 1, \dots, n_i$.

- b. En un DBCA

$$y_{ij} = \mu_0 + \tau_i + \gamma_j + \beta x_{ij} + \epsilon_{ij} \quad \text{o} \quad y_{ij} = \mu + \tau_i + \gamma_j + \beta(x_{ij} - \bar{x}_{..}) + \epsilon_{ij},$$

para $i = 1, \dots, t$, $j = 1, \dots, b$.

c. En un DCL

$$y_{ijk} = \mu_0 + \tau_i + \gamma_j + \delta_k + \beta x_{ij(k)} + \epsilon_{ij(k)} \quad \text{o}$$

$$y_{ijk} = \mu_0 + \tau_i + \gamma_j + \delta_k + \beta (x_{ij(k)} - \bar{x}_{...}) + \epsilon_{ij(k)},$$

para $i, j, k = 1, \dots, t$.

En todos los casos anteriores $\mu_0 = \mu - \beta \bar{x}$.

Lo que se busca en el análisis de covariables (ANCOVA) es ajustar la respuesta de interés (Y 's) por las correspondientes covariables (X 's).

Para cualquier tendencia lineal, los ajustes de Y 's para diferentes X 's se hacen sustrayendo de y_{ij} la cantidad bx_{ij} , es decir, $y_{sij} = y_{ij} - bx_{ij}$, donde y_{sij} es el valor ajustado por efecto de la covariable y b el estimador de β .

En la figura 8.1, se ilustra el concepto de Y cuando los X 's no están sujetos a errores de muestreo y, además, existe una relación lineal entre X y Y . Los valores $y_{si}, y_{si'}$ son comparables directamente, pues tienen la misma media $\bar{x}$.




Figura 8.1: Representación lineal entre X y Y en el modelo con covariable.

En la figura 8.1, se busca traer todos los puntos observados a la línea $X = \bar{x}$ a través de líneas paralelas y de la línea $\hat{y} = \bar{y} + b(x - \bar{x})$, ya que esto elimina los X 's de consideraciones adicionales. Se observa que $\hat{y}_{sij}$ depende de b , lo cual hace que sea una variable aleatoria.

Cuando las observaciones Y 's han sido ajustadas por sus covariables X 's, todas ellas tendrán el mismo valor de X ($X = \bar{x}$). Este proceso de ajuste reduce el problema original de dos variables a un problema de ANOVA con los Y 's ajustados por la covariable.

Sin embargo, se debe tener en cuenta que el ajuste fue hecho por medio de la estimación $\hat{y}_{sij}$ de la relación lineal entre X y Y . Este hecho hace que ANCOVA sea más complejo que el ANOVA.

8.4.1. Análisis de covarianza en un DCA

A continuación se describe el procedimiento básico para el análisis de covarianza en un DCA. Suponiendo que existe una relación lineal entre la respuesta y la covariable, el modelo propuesto es:

$$y_{ij} = \mu + \tau_i + \beta_i(x_{ij} - \bar{x}_{..}) + \epsilon_{ij}, \quad i = 1, \dots, t, \quad j = 1, \dots, r, \quad (8.7)$$

donde y_{ij} hace referencia a la observación j -ésima de la variable respuesta en el tratamiento i -ésimo, x_{ij} es la medición hecha de la covariable concomitante correspondiente a y_{ij} , $\bar{x}_{..}$ es la media de los valores x_{ij} , μ es la media global, τ_i es el efecto del tratamiento i -ésimo, β_i es el coeficiente de regresión lineal en el i -ésimo tratamiento que indica la dependencia entre y_{ij} y x_{ij} , y ϵ_{ij} es el componente de error aleatorio, los cuales se suponen $\epsilon_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$. Además, $\beta_i \neq 0$ y la verdadera relación entre y_{ij} y x_{ij} es lineal, la suma de los tratamientos es cero ($\sum_{i=1}^t \tau_i = 0$) y la variable concomitante x_{ij} no se afecta por los tratamientos.

Adicionalmente, se supone en el modelo (8.7) que los coeficientes de cada tratamiento son idénticos, si esto es cierto, $\beta_i = \beta$ para i es común para todos los tratamientos; para su estimación se combina la información en las muestras de los t -tratamientos, obteniendo de esta manera una estimación ponderada de β .

En la figura 8.2 se ilustra el concepto de relación lineal entre Y y X 's cuando se asume que esta relación es la misma para todos los tratamientos, es decir, las t rectas de regresión son paralelas ($\beta_1 = \dots = \beta_t = \beta$).




Figura 8.2: Gráfico de los datos (x, y) en un DCA.

La hipótesis de interés que se formula para verificar este paralelismo es:

$$H_0 : \beta_1 = \beta_2 = \cdots = \beta_t = \beta.$$

Al hacer el ajuste del modelo (8.7) y el modelo reducido al asumir H_0 cierta, se encuentra el modelo

$$y_{ij} = \mu + \tau_i + \beta(x_{ij} - \bar{x}_{..}) + \epsilon_{ij}, \quad i = 1, \dots, t, j = 1, \dots, r. \quad (8.8)$$

Para obtener el estadístico de prueba a partir del cual se toman decisiones sobre H_0 , se tiene en cuenta el siguiente desarrollo:

- El método de mínimos cuadrados (MC) se aplica por separado a cada conjunto de datos en cada tratamiento. En este caso, se asume que $\sigma_{Y_1/X_1}^2 = \cdots = \sigma_{Y_t/X_t}^2 = \sigma_{Y/X}^2$.
- Si la hipótesis $H_0 : (\beta_1 = \cdots = \beta_t = \beta) / (\sigma_{Y_1/X_1}^2 = \cdots = \sigma_{Y_t/X_t}^2)$ es cierta, se puede obtener una mejor estimación de β ponderando toda la información de las t muestras.

Más aún, la $\sum_{i=1}^t \sum_{j=1}^r (y_{ij} - \hat{y}_{ij})^2$, usando una sola b (estimador de β) deberá ser cercana a la suma de estas diferencias obtenida aplicando el método MC del punto anterior separadamente a cada tratamiento. Por otra parte, si H_0 no es cierta, entonces $\sum_{i=1}^t \sum_{j=1}^r (y_{ij} - \hat{y}_{ij})^2$, obtenida usando una sola b , debería ser diferente de la SC encontrada aplicando separadamente a cada tratamiento y ponderando la $\sum_{i=1}^t \sum_{j=1}^r (y_{ij} - \hat{y}_{ij})^2$ para todo $i = 1, \dots, t$.

Para llevar a cabo la estimación de parámetros, se parte de la función de verosimilitud asociada al modelo (8.7), la cual esta dada por:

$$L = \frac{1}{(2\pi\sigma^2)^{\frac{rt}{2}}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{ij} [y_{ij} - \mu - \tau_i - \beta_i(x_{ij} - \bar{x}_{..})]^2 \right\}.$$

Tomando logaritmo natural al lado y lado de la anterior expresión, se obtiene:

$$\ln L = -\frac{rt}{2} \ln(2\pi) - \frac{rt}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{ij} [y_{ij} - \mu - \tau_i - \beta_i(x_{ij} - \bar{x}_{..})]^2.$$

Al derivar esta función de cada uno de los parámetros (μ , τ_i y β_i) e igualando a cero, se tiene el siguiente conjunto de ecuaciones normales:

- a. $tr\mu + r \sum_{i=1}^t \tau_i + r \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..})\beta_i = y_{..}$
- b. $r\mu + r\tau_i + r(\bar{x}_{i.} - \bar{x}_{..})\beta_i = y_{i.}, i = 1, \dots, t$
- c. $r(\bar{x}_{i.} - \bar{x}_{..})(\mu + \tau_i) + \sum_{j=1}^r (x_{ij} - \bar{x}_{..})^2 \beta_i = \sum_{j=1}^r y_{ij}(x_{ij} - \bar{x}_{..}), i = 1, \dots, t.$

Se observa del sistema anterior que hay $2t + 1$ ecuaciones y el rango es $2t$, luego hay una dependencia lineal. Al imponer las restricciones de no estimabilidad, $\sum_i \tau_i = 0$, se obtiene de a. que:

$$\hat{\mu} = \bar{y}_{..} - \frac{1}{t} \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..}) \hat{\beta}_i \quad (8.9)$$

y de b.,

$$\hat{\tau}_i = \bar{y}_{i.} - \hat{\mu} - \hat{\beta}_i(\bar{x}_{i.} - \bar{x}_{..}), i = 1, \dots, t. \quad (8.10)$$

Al reemplazar la estimación de la ecuación (8.10) en la ecuación c. del sistema de ecuaciones normales, se llega a:

$$\hat{\beta}_i = \frac{\sum_{j=1}^r (x_{ij} - \bar{x}_{i.})(y_{ij} - \bar{y}_{i.})}{\sum_{j=1}^r (x_{ij} - \bar{x}_{i.})^2} = \frac{S_{ixy}}{S_{ixx}}, \quad (8.11)$$

donde $S_{ixy} = \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})(y_{ij} - \bar{y}_{i.})$ y $S_{ixx} = \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})^2$.

A partir de las anteriores estimaciones asociadas a los parámetros en el modelo (8.7), se encuentra la suma de cuadrados del modelo completo,

$$\begin{aligned} SCMC &= \hat{\mu}y_{..} + \sum_{i=1}^t \hat{\tau}_i y_{i.} + \sum_{i=1}^t \sum_{j=1}^r \hat{\beta}_i (x_{ij} - \bar{x}_{..}) y_{ij} \\ &= r \sum_{i=1}^t \bar{y}_{i.}^2 - \sum_{i=1}^t \hat{\beta}_i (\bar{x}_{i.} - \bar{x}_{..}) y_{i.} + \sum_{i=1}^t \sum_{j=1}^r \hat{\beta}_i (x_{ij} - \bar{x}_{..}) y_{ij} \\ &= r \sum_{i=1}^t \bar{y}_{i.}^2 + \sum_{i=1}^t \frac{S_{ixy}^2}{S_{ixx}}. \end{aligned}$$

La anterior suma de cuadrados tiene $2t$ grados de libertad.

Similarmente, para el modelo (8.8), las ecuaciones normales son:

$$\begin{aligned} tr\mu + r \sum_{i=1}^t \tau_i + r\beta \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..}) &= y_{..} \\ r\mu + r\tau_i + r(\bar{x}_{i.} - \bar{x}_{..})\beta &= y_{i.}, \quad i = 1, \dots, t \\ r \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..})(\mu + \tau_i) + \beta \sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{..})^2 &= \sum_{i=1}^t \sum_{j=1}^r y_{ij}(x_{ij} - \bar{x}_{..}). \end{aligned}$$

Entonces, al solucionar el anterior sistema de ecuaciones, se obtienen las siguientes estimaciones:

$$\hat{\mu} = \bar{y}_{..}, \quad \hat{\tau}_i = \bar{y}_{i.} - \bar{y}_{..} - \hat{\beta}(\bar{x}_{i.} - \bar{x}_{..}),$$

donde

$$\begin{aligned} \hat{\beta} &= \frac{\sum_{i=1}^t \sum_{j=1}^r x_{ij}y_{ij} - \frac{1}{r} \sum_{i=1}^t y_{i.}x_{i.}}{\sum_{i=1}^t \sum_{j=1}^r x_{ij}^2 - \frac{1}{r} \sum_{i=1}^t x_{i.}^2} = \frac{\sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})(y_{ij} - \bar{y}_{i.})}{\sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})^2} \\ &= \frac{\sum_{i=1}^t S_{ixy}}{\sum_{i=1}^t S_{ixx}} = \frac{E_{xy}}{E_{xx}}, \end{aligned} \quad (8.12)$$

con $E_{xy} = \sum_{i=1}^t S_{ixy}$ y $E_{xx} = \sum_{i=1}^t S_{ixx}$. Obsérvese que, en este caso, $\hat{\beta}$ es un promedio ponderado de los estimadores individuales de β_i .

Al igual que en el modelo completo, con base en las anteriores estimaciones, se encuentra la suma de cuadrados del modelo reducido (SCMR), obtenido al suponer la hipótesis $H_0 : \beta_1 = \beta_2 = \dots = \beta_t = \beta$ cierta, es decir,

$$\begin{aligned} SCMR &= R(\mu, \tau, \beta) \\ &= \hat{\mu}y_{..} + \sum_{i=1}^t \hat{\tau}_i y_{i.} + \hat{\beta} \sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})y_{ij} \\ &= r \sum_{i=1}^t \bar{y}_{i.}^2 - \hat{\beta} \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..})y_{i.} + \hat{\beta} \sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})y_{ij} \\ &= r \sum_{i=1}^t \bar{y}_{i.}^2 + \frac{(E_{xy})^2}{E_{xx}} \\ &= \frac{y_{..}^2}{tr} + T_{yy} + \frac{(E_{xy})^2}{E_{xx}}, \end{aligned}$$

donde $T_{yy} = r \sum_{i=1}^t (\bar{y}_{i.} - \bar{y}_{..})^2 = r \sum_{i=1}^t \bar{y}_{i.}^2 - \frac{y_{..}^2}{tr}$. Esta suma de cuadrados tiene $t + 1$ grados de libertad.

A partir de la suma de cuadrados para los modelos (8.7) y (8.8), se obtiene la estadística F para llevar a cabo la prueba sobre la igualdad de pendientes,

$$F = \frac{t(r-2)(SCMC - SCMR)}{(t-1) \left(\sum_{i=1}^t \sum_{j=1}^r y_{ij}^2 - SCMC \right)},$$

con $t - 1$ y $t(r - 2)$ grados de libertad.

El anterior estadístico de prueba se puede escribir de la forma:

$$F = \frac{\frac{1}{v_1} \left(\sum_{i=1}^t \frac{S_{ixy}^2}{S_{iix}} - \frac{E_{xy}^2}{E_{xx}} \right)}{\frac{1}{v_2} \left(\sum_{i=1}^t S_{iyy} - \sum_{i=1}^t \frac{S_{ixy}^2}{S_{iix}} \right)}, \quad (8.13)$$

donde $S_{iix} = \sum_{j=1}^r (x_{ij} - \bar{x}_{i.})^2$, $v_1 = 2t - (t + 1) = t - 1$ y $v_2 = tr - 2t = t(r - 2)$. Si $F > F_{(t-1, t(r-2), \alpha)}$, con un nivel de significación α preestablecido, entonces se rechaza H_0 y se concluye que al menos una pendiente no tiene la misma tendencia.

Si H_0 se rechaza, se deben investigar más detalladamente los datos, por ejemplo, graficando o realizando una prueba formal para hallar si el no paralelismo se debe a un tratamiento que ocasiona la “violación” de este supuesto. Se puede eliminar el tratamiento y continuar con el análisis de los otros tratamientos de la manera usual. Si lo anterior no es plausible, es difícil decidir que hacer. En cualquier caso, el modelo (8.8) no es apropiado y, de este modo, el modelo (8.7) se debe utilizar.

Ejemplo 8.9. *Un ingeniero estudia el efecto de la rapidez de corte sobre el índice de metal eliminado en una operación de maquinado. Sin embargo, el índice de metal eliminado se relaciona también con la dureza del material de prueba. Se realizan doce observaciones de cada rapidez de corte. La cantidad de metal eliminado (y) y la dureza del ejemplar (x) se presentan en la tabla 8.14.*

Tabla 8.14: Rapidez de corte en rpm sobre la cantidad de metal eliminado (y) y dureza del material (x)

Rapidez de corte (rpm)					
1000		1200		1400	
x	y	x	y	x	y
70	72	90	70	115	76
72	76	93	76	110	73
75	72	95	68	118	72
76	76	96	76	122	82
80	82	97	78	125	78
81	76	102	78	125	87
85	80	105	76	130	85
83	78	108	86	133	88
91	86	110	80	135	82
92	86	115	86	119	81
98	96	117	85	140	88
100	90	120	90	140	92

En este caso, las estimaciones de los parámetros involucrados en el modelo (8.7) son:

$$\hat{\beta}_1 = \frac{S_{1xy}}{S_{1xx}} = \frac{748.167}{1074.917} = 0.696$$

$$\hat{\beta}_2 = \frac{S_{2xy}}{S_{2xx}} = \frac{653}{1114} = 0.586$$

$$\hat{\beta}_3 = \frac{S_{3xy}}{S_{3xx}} = \frac{574}{1046} = 0.549$$

$$\hat{\mu} = 80.639 - \frac{(-3.104)}{3} = 81.674$$

$$\hat{\tau}_1 = 80.833 - 81.674 - 0.696(83.583 - 104.528) = 13.737$$

$$\hat{\tau}_2 = 79.083 - 81.674 - 0.586(104 - 104.528) = -2.280$$

$$\hat{\tau}_3 = 82.000 - 81.674 - 0.549(126 - 104.528) = -11.457.$$

Con estas estimaciones, se encuentra que la suma de cuadrados del modelo completo es:

$$SCMC = 12(19512.201) + 1218.501 = 235364.913.$$

Para el modelo (8.8), se encontraron las siguientes estimaciones:

$$\hat{\mu} = 80.639, \quad \hat{\beta} = \frac{E_{xy}}{E_{xx}} = \frac{1975.167}{3234.917} = 0.611,$$

$$\hat{\tau}_1 = 12.983, \quad \hat{\tau}_2 = -1.233 \quad y \quad \hat{\tau}_3 = -11.749$$

La suma de cuadrados para el modelo reducido es:

$$SCMR = 12(19512.201) + \frac{(1975.167)^2}{3234.917} = 235352.409.$$

Para este estudio, se observa que las estimaciones de β_1 , β_2 y β_3 están muy cercanas a la estimación de β , por lo cual se podría asumir la misma tendencia para los tres niveles de rapidez. Este hecho se puede visualizar también a través de la figura 8.3.




Figura 8.3: Cantidad de metal eliminado (y) contra dureza (x) a través de los tratamientos.

El estadístico de prueba, para contrastar la hipótesis $H_0 : \beta_1 = \beta_2 = \beta_3 = \beta$, es

$$F = \frac{3(10)(235364.917 - 235352.409)}{(2)(235677 - 235364.917)} = 0.601.$$

Como este valor es menor que $F_{(2,30,0.05)} = 3.316$, entonces no se rechaza H_0 y se concluye que todas las pendientes tienen la misma tendencia.

La suma de cuadrados del error asociada al modelo (8.8) es:

$$\begin{aligned} SCE &= \sum_{i=1}^t \sum_{j=1}^r y_{ij}^2 - R(\mu, \tau, \beta) \\ &= \sum_{i=1}^t \sum_{j=1}^r y_{ij}^2 - \frac{y_{..}^2}{tr} - T_{yy} - \frac{E_{xy}^2}{E_{xx}} \\ &= S_{yy} - T_{yy} - \frac{E_{xy}^2}{E_{xx}} \\ &= E_{yy} - \frac{E_{xy}^2}{E_{xx}}, \end{aligned}$$

donde $S_{yy} = \sum_{i=1}^t \sum_{j=1}^r (y_{ij} - \bar{y}_{..})^2 = \sum_{i=1}^t \sum_{j=1}^r y_{ij}^2 - \frac{y_{..}^2}{tr}$ y $E_{yy} = S_{yy} - T_{yy}$. Esta suma de cuadrados tiene $t(r-1) - 1$ grados de libertad.

La varianza de error experimental se estima como:

$$\hat{\sigma}^2 = CME = \frac{1}{t(r-1) - 1} \left(E_{yy} - \frac{E_{xy}^2}{E_{xx}} \right). \quad (8.14)$$

Si ahora, se tiene interés en la hipótesis de igualdad de efectos de tratamientos, es decir, $H_0 : \tau_1 = \dots = \tau_t$ en la construcción del estadístico de prueba, se parte del modelo reducido bajo H_0

$$y_{ij} = \mu + \beta(x_{ij} - \bar{x}_{..}) + \epsilon_{ij}.$$

El anterior modelo es el asociado con una regresión lineal simple, y sus ecuaciones normales son:

$$\begin{aligned} tr \hat{\mu} &= y_{..} \\ \hat{\beta} S_{xx} &= S_{xy} \end{aligned}$$

con

$$S_{xx} = \sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{..})^2 = \sum_{i=1}^t \sum_{j=1}^r x_{ij}^2 - \frac{x_{..}^2}{tr}$$

y

$$S_{xy} = \sum_{i=1}^t \sum_{j=1}^r (x_{ij} - \bar{x}_{..})(y_{ij} - \bar{y}_{..}) = \sum_{i=1}^t \sum_{j=1}^r x_{ij}y_{ij} - \frac{x_{..}y_{..}}{tr}.$$

De las ecuaciones normales, se llega a las siguientes estimaciones de los parámetros:

$$\hat{\mu} = \bar{y}_{..} \quad y \quad \hat{\beta} = \frac{S_{xy}}{S_{xx}}.$$

La reducción en la suma de cuadrados total debida al ajuste del modelo reducido es:

$$\begin{aligned} R(\mu, \beta) &= \hat{\mu}y_{..} + \hat{\beta}S_{xy} \\ &= \frac{y_{..}^2}{tr} + \frac{S_{xy}^2}{S_{xx}}. \end{aligned}$$

Esta suma de cuadrados tiene asociados dos grados de libertad.

La suma de cuadrados asociada con la hipótesis $H_0 : \tau_1 = \cdots = \tau_t$ es:

$$\begin{aligned} R(\tau/\mu, \beta) &= R(\mu, \tau, \beta) - R(\mu, \beta) \\ &= S_{yy} - \frac{S_{xy}^2}{S_{xx}} - \left(E_{yy} - \frac{E_{xy}^2}{E_{xx}} \right) \\ &= SCE' - SCE, \end{aligned}$$

utilizando $T_{yy} = S_{yy} - E_{yy}$ y $SCE' = S_{yy} - \frac{S_{xy}^2}{S_{xx}}$. Esta suma de cuadrados $R(\tau/\mu, \beta)$ tiene asociados $t - 1$ grados de libertad.

En la anterior expresión, S_{xy}^2/S_{xx} es la reducción de la suma de cuadrados de y obtenida a través de la regresión lineal de y sobre x . Por consiguiente, para llevar a cabo la prueba de hipótesis de no efecto de los tratamientos, se hace uso del siguiente estadístico de prueba:

$$\begin{aligned} F_C &= \frac{SCE' - SCE}{(t-1)\hat{\sigma}^2} \\ &= \frac{1}{(t-1)\hat{\sigma}^2} \left[S_{yy} - \frac{S_{xy}^2}{S_{xx}} - \left(E_{yy} - \frac{E_{xy}^2}{E_{xx}} \right) \right] \\ &= \frac{1}{(t-1)\hat{\sigma}^2} \left[T_{yy} + E_{yy} - \frac{(T_{xy} + E_{xy})^2}{T_{xx} + E_{xx}} - \left(E_{yy} - \frac{E_{xy}^2}{E_{xx}} \right) \right]. \end{aligned}$$

Si la hipótesis nula es cierta, F_C se distribuye como $F_{(t-1, t(r-1)-1)}$. En este caso, se rechaza $H_0 : \tau_1 = \cdots = \tau_t$ si $F_C > F_{(t-1, t(r-1)-1, \alpha)}$.

Los resultados anteriores se resumen en la tabla 8.15. Se debe tener en cuenta que $S_{xx} = T_{xx} + E_{xx}$, $S_{xy} = T_{xy} + E_{xy}$ y $S_{yy} = T_{yy} + E_{yy}$, con $T_{xx} = r \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..})^2 = \frac{1}{r} \sum_{i=1}^t x_{i.}^2 - \frac{x_{..}^2}{tr}$ y $T_{xy} = r \sum_{i=1}^t (\bar{x}_{i.} - \bar{x}_{..})(\bar{y}_{i.} - \bar{y}_{..}) = \frac{1}{r} \sum_{i=1}^t x_{i.}y_{i.} - \frac{x_{..}y_{..}}{tr}$.

Tabla 8.15: Análisis de covarianza para un DCA con covariable

		Sumas de cuadrados			Sumas de cuadrados ajustadas por la regresión			
C de V	gl	$\sum x^2$	$\sum xy$	$\sum y^2$	gl	SC	CM	F
Trats	$t - 1$	T_{xx}	T_{xy}	T_{yy}				
Error	$t(r - 1)$	E_{xx}	E_{xy}	E_{yy}	rt-t-1	SCE	$\frac{SCE}{t(r-1)-1}$	
Total	$rt - 1$	S_{xx}	S_{xy}	S_{yy}	rt-2	SCE'		
Tratamientos ajustados					t-1	$SCE' - SCE$	$\frac{SCE' - SCE}{t-1}$	F_C

La hipótesis $H_0 : \beta = 0$ puede juzgarse utilizando el estadístico de prueba

$$F = \frac{E_{xy}^2/E_{xx}}{CME},$$

que bajo la hipótesis nula se distribuye como $F_{(1,t(r-1)-1)}$, y se rechaza $H_0 : \beta = 0$ si $F > F_{(1,t(r-1)-1,\alpha)}$.

Ejemplo 8.10. Retomando los datos del ejemplo 8.9, se desea contrastar ahora la hipótesis $H_0 : \tau_1 = \tau_2 = \tau_3$.

El gráfico de dispersión de la cantidad de metal eliminado contra la dureza (figura 8.4) indica una relación lineal entre estas dos variables, siendo apropiado eliminar el efecto de la dureza sobre la cantidad de metal eliminado mediante un análisis de covarianza.




Figura 8.4: Cantidad de metal eliminado (y) contra dureza (x).

Suponiendo que la relación lineal entre la cantidad de metal eliminado y dureza es apropiado, se propone el modelo

$$y_{ij} = \mu + \tau_i + \beta(x_{ij} - \bar{x}_{..}) + e_{ij},$$

con $i = 1, 2, 3$ y $j = 1, \dots, 12$. Las diferentes sumas de cuadrados con estos datos son:

$$\begin{aligned} S_{yy} &= \sum_{i=1}^3 \sum_{j=1}^{12} y_{ij}^2 - \frac{y_{..}^2}{tr} = (72)^2 + (76)^2 + \dots + (92)^2 - \frac{(2903)^2}{(3)(12)} \\ &= 1582.30 \end{aligned}$$

$$\begin{aligned} S_{xx} &= \sum_{i=1}^3 \sum_{j=1}^{12} x_{ij}^2 - \frac{x_{..}^2}{tr} = (70)^2 + (72)^2 + \dots + (140)^2 - \frac{(3763)^2}{(3)(12)} \\ &= 14034.97 \end{aligned}$$

$$\begin{aligned}
S_{xy} &= \sum_{i=1}^3 \sum_{j=1}^{12} x_{ij}y_{ij} - \frac{x_{..}y_{..}}{tr} \\
&= (70)(72) + (72)(76) + \cdots + (140)(92) - \frac{(3763)(2903)}{(3)(12)} \\
&= 2286.86 \\
T_{yy} &= \frac{1}{r} \sum_{i=1}^3 y_{i.}^2 - \frac{y_{..}^2}{tr} = \frac{1}{12} [(970)^2 + (949)^2 + (984)^2] - \frac{(2903)^2}{(3)(12)} = 51.72 \\
T_{xx} &= \frac{1}{r} \sum_{i=1}^3 x_{i.}^2 - \frac{x_{..}^2}{tr} = \frac{1}{12} [(1003)^2 + (1248)^2 + (1512)^2] - \frac{(3763)^2}{(3)(12)} \\
&= 10800.05 \\
T_{xy} &= \frac{1}{r} \sum_{i=1}^3 x_{i.}y_{i.} - \frac{x_{..}y_{..}}{tr} \\
&= \frac{1}{12} [(1003)(970) + (1248)(949) + (1512)(984)] - \frac{(3763)(2903)}{(3)(12)} \\
&= 311.69.
\end{aligned}$$

Con base en las anteriores sumas de cuadrados, se tiene

$$SCE' = S_{yy} - \frac{S_{xy}^2}{S_{xx}} = 1582.30 - \frac{(2286.86)^2}{14034.97} = 1209.68,$$

con $tr - 2 = (3)(12) - 2 = 34$ grados de libertad. Además,

$$SCE = E_{yy} - \frac{E_{xy}^2}{E_{xx}} = 1530.58 - \frac{(1975.16)^2}{3234.91} = 324.59,$$

con $t - 1 = 3 - 1 = 2$ grados de libertad. Estos resultados se resumen en la tabla 8.16.

Tabla 8.16: Resultados para el ANCOVA con los datos de la cantidad de metal eliminado en una operación de maquinado.

C de V	gl	Sumas de cuadrados			gl	Sumas de cuadrados ajustadas por la regresión		
		$\sum x^2$	$\sum xy$	$\sum y^2$		SC	CM	F
Rapidez	2	10800.05	311.69	51.72				
Error	33	3234.91	1975.16	1530.58	32	324.59	10.14	
Total	35	14034.97	2286.86	1582.30	34	1209.68		
Tratamientos ajustados					2	885.09	442.54	43.63

Para contrastar la hipótesis de diferencias en la cantidad de metal eliminado entre los diferentes niveles de rapidez, es decir, $H_0 : \tau_1 = \tau_2 = \tau_3$. El estadístico de prueba es:

$$F_C = \frac{SCE' - SCE}{(t-1)CME} = \frac{885.09}{(2)(10.14)} = 43.63.$$

Al comparar este valor con $F_{(2,32,0.05)} = 3.295$, se encuentra que se rechaza la hipótesis nula. Por lo tanto, hay evidencia del efecto de la rapidez de corte sobre el índice del metal eliminado en la operación de maquinado, es decir, hay efecto de la covariable.

La hipótesis $H_0 : \beta = 0$ se verifica mediante el estadístico de prueba

$$F = \frac{(E_{xy})^2/E_{xx}}{CME} = \frac{(1975.16)^2/(3234.91)}{10.14} = 118.89$$

y, puesto que $F_{(1,32,0.05)} = 4.149$, se rechaza la hipótesis $H_0 : \beta = 0$. Por lo tanto, existe una relación lineal entre la cantidad de metal eliminado y la dureza, con lo cual se concluye que el ajuste proporcionado por el análisis de covarianza fue necesario.

El MELI del contraste $\sum_{i=1}^t c_i \tau_i = 0$, con $\sum_{i=1}^t c_i = 0$, está dado por

$$\sum_{i=1}^t c_i \hat{\tau}_i = \sum_{i=1}^t c_i \bar{y}_{i.} - \hat{\beta} \sum_{i=1}^t c_i \bar{x}_{i.}.$$

Como un caso especial se tiene

$$\begin{aligned} \widehat{\tau_i - \tau_{i'}} &= \hat{\tau}_i - \hat{\tau}_{i'} = \bar{y}_{i.} - \bar{y}_{i' .} - \hat{\beta} (\bar{x}_{i.} - \bar{x}_{i' .}) \\ &= \bar{y}_{A_i} - \bar{y}_{A_{i'}}, \end{aligned} \quad (8.15)$$

donde $\bar{y}_{A_i} = \bar{y}_{i.} - \hat{\beta} (\bar{x}_{i.} - \bar{x}_{..})$ es el valor de y en $x = \bar{x}_{..}$ para el tratamiento i y el parámetro β es estimado como en (8.12). El estimador anterior es la correspondiente diferencia entre las medias de los tratamientos más un ajuste por las diferencias en las covariables para los dos tratamientos. Por lo tanto, $\bar{y}_{A_i} - \bar{y}_{A_{i'}}$ representa la diferencia entre un par de tratamientos ajustada por covariable.

Para obtener las varianzas de los estimadores anteriores, como $\bar{y}_{i.}$ y $\hat{\beta}$ no están correlacionados, siguiendo a Hinkelman y Kempthorne (1994) se encuentra:

$$\begin{aligned} Var(\hat{\beta}) &= \frac{\sigma^2}{E_{xx}} \\ Var(\hat{\mu} + \hat{\tau}_i) &= \left(\frac{1}{r} + \frac{(\bar{x}_{i.} - \bar{x}_{..})^2}{E_{xx}} \right) \sigma^2 \end{aligned}$$

$$Cov(\hat{\mu} + \hat{\tau}_i, \hat{\mu} + \hat{\tau}_{i'}) = \frac{(\bar{x}_{i.} - \bar{x}_{..})(\bar{x}_{i'.} - \bar{x}_{..})}{E_{xx}} \sigma^2, \quad i \neq i'$$

$$Var\left(\sum_{i=1}^t c_i \hat{\tau}_i\right) = \left(\frac{\sum_{i=1}^t c_i^2}{r} + \frac{(\sum_{i=1}^t c_i \bar{x}_{i.})^2}{E_{xx}}\right) \sigma^2. \quad (8.16)$$

Como en general no se conoce σ^2 , entonces se reemplaza por la estimación encontrada en (8.14).

Por lo general, en este tipo de modelos la hipótesis $H_0 : \tau_1 = \tau_2 = \dots = \tau_t$ es de menor importancia y produce menos información que hipótesis específicas de la forma $\sum_{i=1}^t c_i \tau_i = 0$, con $\sum_{i=1}^t c_i = 0$, entonces mediante el uso de la varianza del contraste (8.16) y la estimación de la varianza (8.14) se pueden juzgar las hipótesis con un solo grado de libertad, bien sea dentro del contexto del análisis de varianza usando F o con la prueba t . En cualquiera de los dos casos, se obtiene la suma de cuadrados asociada al contraste como:

$$SC\left(\sum_{i=1}^t c_i \tau_i\right) = \frac{\left(\sum_{i=1}^t c_i \hat{\tau}_i\right)^2}{\frac{\sum_{i=1}^t c_i^2}{r} + \frac{\left(\sum_{i=1}^t c_i \bar{x}_{i.}\right)^2}{E_{xx}}}$$

y, de esta manera,

$$F = \frac{SC\left(\sum_{i=1}^t c_i \tau_i\right)}{CME} \quad (8.17)$$

o, equivalentemente,

$$t = \frac{\sum_{i=1}^t c_i \hat{\tau}_i}{\sqrt{\left(\frac{\sum_{i=1}^t c_i^2}{r} + \frac{\left(\sum_{i=1}^t c_i \bar{x}_{i.}\right)^2}{E_{xx}}\right) CME}} \quad (8.18)$$

Si $F > F_{(1, t(r-1)-1, \alpha/2)}$ o $t > t_{(t(r-1)-1, \alpha/2)}$, se rechaza la hipótesis nula $H_0 : \sum_{i=1}^t c_i \tau_i = 0$.

Ejemplo 8.11. Retomando los datos del ejemplo 8.9, las medias de los tratamientos ajustadas son las siguientes:

$$\bar{y}_{A_1} = \bar{y}_1. - \hat{\beta}(\bar{x}_1. - \bar{x}_{..}) = 93.62$$

$$\bar{y}_{A_2} = \bar{y}_2. - \hat{\beta}(\bar{x}_2. - \bar{x}_{..}) = 79.41$$

y

$$\bar{y}_{A_3} = \bar{y}_{3.} - \hat{\beta}(\bar{x}_{3.} - \bar{x}_{..}) = 68.89.$$

Al comparar las medias ajustadas con las medias no ajustadas de los tratamientos,

$$\bar{y}_{1.} = 80.83, \quad \bar{y}_{2.} = 79.08 \quad \text{y} \quad \bar{y}_{3.} = 82.$$

Se observa que las medias ajustadas se encuentran mucho más lejanas entre sí. Esto evidencia aún más que el análisis de covarianza era necesario.

Suponga ahora que se desea contrastar la hipótesis $H_0^{(1)} : 2\tau_1 = \tau_2 + \tau_3$. Haciendo uso del estadístico de prueba (8.17) o (8.18), en el cual

$$\begin{aligned} \sum_{i=1}^3 c_i \hat{\tau}_i &= \sum_{i=1}^3 c_i \bar{y}_{i.} - \hat{\beta} \sum_{i=1}^3 c_i \bar{x}_{i.} \\ &= [2(80.83) - 79.08 - 82] - 0.6105[2(83.58) - 104 - 126] \\ &= 38.95, \end{aligned}$$

entonces

$$t = \frac{38.95}{\sqrt{\left(\frac{6}{12} + \frac{(-62.83)^2}{3234.92}\right)} (10.14)} = 9.33.$$

Se rechaza la hipótesis $H_0^{(1)} : 2\tau_1 = \tau_2 + \tau_3$, puesto que $t_{(32, 0.025)} = 2.037$. De este modo, se puede concluir que el efecto promedio del índice de metal eliminado en la operación de maquinado a través de la rapidez de corte a 1000 rpm no es el mismo que el producido sobre el promedio de los niveles de rapidez de corte 1200 y 1400 rpm.

Un supuesto básico en el análisis de covarianza es que los tratamientos están libres de la influencia de la covariable X ; la técnica de análisis elimina el efecto de las variaciones en las $\bar{x}_{i.}$. Sin embargo, si la variabilidad en las $\bar{x}_{i.}$ se debe en parte a los tratamientos, entonces el análisis de covarianza elimina parte del efecto de que los tratamientos. Por lo tanto, deberá tenerse una seguridad razonable que los tratamientos no afectan a los valores x_{ij} . En algunos experimentos esto puede ser obvio a partir de la naturaleza de la covariable, mientras que en otros, esto puede ser más dudoso.

8.4.2. Covariables afectadas por los tratamientos

Para entender intuitivamente el problema que se crea cuando las covariables son afectadas por los tratamientos, considere la figura 8.5 (Hinkelman y Kempthorne 1994). En este caso, los valores bajos de Y están asociados con valores bajos de X para el primer tratamiento T_1 y los valores altos en Y están asociados con valores altos en X para el segundo tratamiento T_2 .




Figura 8.5: Covariables afectadas por los tratamientos.

Si se aplica el análisis de covarianza para comparar los dos tratamientos, estos se comparan con respecto a $x = \bar{x}_{..}$, un valor que no se alcanza por alguno de los dos tratamientos. Cuando esto sucede se dice que la covariable es afectada por los tratamientos.

Según Hinkelmann y Kempthorne (1994), si las covariables son observadas antes de aplicar los tratamientos a las unidades experimentales, estas no son afectadas por los tratamientos. Sin embargo, en este caso una situación como la presentada en la figura 8.5 puede suceder por dos razones: i) debido a una respuesta particular en la forma como se llevó a cabo la aleatorización del proceso y ii) debido a la falta de aleatorización.

8.4.3. Análisis de covarianza en un DBCA

Para este diseño, se parte del modelo estadístico de bloques con covariables:

$$y_{ij} = \mu + \tau_i + \gamma_j + \beta(x_{ij} - \bar{x}_{..}) + e_{ij}, \quad (8.19)$$

con $i = 1, 2, \dots, t$ (número de tratamientos) y $j = 1, 2, \dots, r$ (número de bloques). Los supuestos que se hacen para este modelo son básicamente los mismos del DCA con una covariable:

1. Los X son fijos, medidos sin error e independientes de los tratamientos.
2. La regresión de Y con respecto a X , luego de eliminar las diferencias debidas a los tratamientos y a los bloques, es lineal e independiente de bloques y tratamientos.
3. Los errores son independientes e idénticamente distribuidos como normal con media cero y varianza común.

La varianza de los residuos se estima siguiendo la metodología de los mínimos cuadrados. Las estimaciones obtenidas con este método son las siguientes:

$$\begin{aligned}\hat{\mu} &= \bar{y}_{..}, & \hat{\beta} &= \frac{E_{xy}}{E_{xx}} \quad y \\ \hat{\tau}_i &= \bar{y}_{i.} - \bar{y}_{..} - \hat{\beta}(\bar{x}_{i.} - \bar{x}_{..}),\end{aligned}\quad (8.20)$$

y un estimador insesgado de la varianza poblacional, σ^2 , es:

$$\hat{\sigma}^2 = \frac{1}{(r-1)(t-1)-1} E_A = CME_A, \quad (8.21)$$

donde $E_A = E_{yy} - (E_{xy}^2/E_{xx})$ y, E_{xx} , E_{xy} y E_{yy} corresponden a las sumas de cuadrados para el error experimental como se presenta en la tabla 8.17.

Tabla 8.17: Análisis de covarianza para un DBCA

C de V	Sumas de cuadrados y productos				Ajustados para la regresión		
	gl	$\sum x^2$	$\sum xy$	$\sum y^2$	gl	SC	CM
Total	$rt - 1$	t_{xx}	t_{xy}	t_{yy}			
Bloques (B)	$r - 1$	B_{xx}	B_{xy}	B_{yy}			
Trats (T)	$t - 1$	T_{xx}	T_{xy}	T_{yy}			
Error (E)	$(r-1)(t-1)$	E_{xx}	E_{xy}	E_{yy}	$(r-1)(t-1)-1$	E_A	CME_A
$S = T + E$	$r(t-1)$	S_{xx}	S_{xy}	S_{yy}	$r(t-1)-1$	S_A	
Trats(Ajustado)					$t - 1$	T_A	CMT_A

Algunos de los resultados de la tabla 8.17 se obtienen a partir de las siguientes expresiones.

Las sumas de cuadrados y productos cruzados para el total

$$\begin{aligned}t_{xx} &= \sum_{ij} (x_{ij} - \bar{x}_{..})^2 = \sum_{ij} x_{ij}^2 - \frac{x_{..}^2}{rt} \\ t_{yy} &= \sum_{ij} (y_{ij} - \bar{y}_{..})^2 = \sum_{ij} y_{ij}^2 - \frac{y_{..}^2}{rt} \\ t_{xy} &= \sum_{ij} (x_{ij} - \bar{x}_{..})(y_{ij} - \bar{y}_{..}) = \sum_{ij} x_{ij}y_{ij} - \frac{x_{..}y_{..}}{rt}.\end{aligned}$$

Sumas de cuadrados y productos cruzados para bloques

$$B_{xx} = \sum_{j=1}^r \frac{x_{.j}^2}{t} - \frac{x_{..}^2}{tr}, \quad B_{yy} = \sum_{j=1}^r \frac{y_{.j}^2}{t} - \frac{y_{..}^2}{tr} \quad y \quad B_{xy} = \sum_{j=1}^r \frac{x_{.j}y_{.j}}{t} - \frac{x_{..}y_{..}}{tr}.$$

Sumas de cuadrados y productos cruzados para tratamientos

$$T_{xx} = \sum_{i=1}^t \frac{x_{i.}^2}{r} - \frac{x_{..}^2}{tr}, \quad T_{yy} = \sum_{i=1}^t \frac{y_{i.}^2}{r} - \frac{y_{..}^2}{tr} \quad y \quad T_{xy} = \sum_{i=1}^t \frac{x_{i.}y_{i.}}{r} - \frac{x_{..}y_{..}}{tr}.$$

Sumas de cuadrados y productos para el error

$$E_{xx} = t_{xx} - B_{xx} - T_{xx}, \quad E_{yy} = t_{yy} - B_{yy} - T_{yy} \quad \text{y} \quad E_{xy} = t_{xy} - B_{xy} - T_{xy}.$$

Adicionalmente,

$$S_{xx} = T_{xx} + E_{xx}, \quad S_{yy} = T_{yy} + E_{yy}, \quad S_{xy} = T_{xy} + E_{xy}$$

$$S_A = S_{yy} - \frac{S_{xy}^2}{S_{xx}} \quad \text{y} \quad T_{A(\text{ajustado})} = S_A - E_A.$$

Finalmente el cuadrado medio de los tratamientos ajustado por covariable se obtiene como

$$CMT_{A(\text{ajustado})} = \frac{S_A - E_A}{t - 1}.$$

A partir de la tabla 8.17 se puede llevar a cabo tanto un análisis de varianza para la variable Y , antes del ajuste, como un análisis de varianza para X ; una vez hecho el ajuste, se realiza el análisis de covarianza. Al comparar los resultados del análisis de varianza y de covarianza, se puede ver el efecto de la covariable.

Es de interés en este ensayo llevar a cabo el análisis sobre igualdad de tratamientos, según la siguiente hipótesis:

$$H_0 : \tau_1 = \cdots = \tau_t$$

vs

$$H_a : \text{al menos un } \tau_i \neq \tau_{i'}, \quad i \neq i', \quad i, i' = 1, 2, \dots, t$$

Antes del ajuste, el estadístico de prueba es

$$F = \frac{\frac{T_{yy}}{t-1}}{\frac{E_{yy}}{(t-1)(r-1)}} = \frac{CMT_{yy}}{CME_{yy}}.$$

Si este valor es mayor que el valor de la tabla $F_{(t-1, (t-1)(r-1), \alpha)}$ se rechaza H_0 .

Cuando el promedio de tratamientos ha sido ajustado, entonces se debe llevar a cabo la prueba de igualdad de efectos de tratamiento ajustado a partir del estadístico

$$F = \frac{CMT_{A(\text{ajustado})}}{CME_A}$$

Al igual que lo planteado en el DCA con covariable, si este valor es mayor que $F_{(t-1, (t-1)(r-1)-1, \alpha)}$, se rechaza H_0 y se concluye que hay diferencia de los tratamientos cuando hay efecto de la covariable.

Para contrastar la hipótesis $H_0 : \beta = 0$ contra $H_a : \beta \neq 0$, se hace uso del estadístico de prueba

$$F = \frac{E_{xy}^2/E_{xx}}{CME_A}.$$

Si este valor es mayor que $F_{(1, (t-1)(r-1)-1, \alpha)}$, se rechaza la hipótesis de no asociación entre la covariable y la variable respuesta.

Si hay efecto de covariable (hay una reducción real del error) se debe ajustar las medias de los tratamientos por efecto de esta covariable. En este caso, la ecuación para la media ajustada es:

$$\bar{y}_{i.(ajustado)} = \bar{y}_{i.} - \hat{\beta}(\bar{x}_{i.} - \bar{x}_{..}), \quad i = 1, \dots, t.$$

La varianza de la media ajustada dada en la expresión anterior es:

$$\widehat{Var}(\bar{y}_{i.(ajustado)}) = CME_A \left(\frac{1}{r} + \frac{(\bar{x}_{i.} - \bar{x}_{..})^2}{E_{xx}} \right)$$

y la varianza de la diferencia de dos medias ajustadas está dado por:

$$\widehat{Var}(\bar{y}_{i.} - \bar{y}_{i'.})_{(ajustado)} = CME_A \left(\frac{2}{r} + \frac{(\bar{x}_{i.} - \bar{x}_{i'.})^2}{E_{xx}} \right).$$

Esta ecuación se recomienda cuando los grados de libertad para el error son menores de 20. Si son mayores de 20, se puede usar la siguiente aproximación sugerida por Finney (1946):

$$\widehat{Var}(\bar{y}_{i.} - \bar{y}_{i'.})_{(ajustado)} = \frac{2CME_A}{r} \left(1 + \frac{T_{xx}}{(t-1)E_{xx}} \right).$$

Finalmente, se tiene interés en determinar si hay alguna ganancia en el modelo por el uso de la covariable; para tal fin, se debe calcular la eficiencia relativa (ER) entre el modelo sin y con covariable, esta se obtiene con la expresión:

$$ER = \frac{CME_{yy}}{CME_A \left(1 + \frac{CMT_{xx}}{E_{xx}} \right)} \times 100.$$

Si $ER > 1$, entonces es más eficiente un diseño en covariables. En otras palabras, si ese valor es, por ejemplo 150 %, quiere decir que 100 repeticiones con covarianza son tan efectivas como 150 repeticiones sin covarianza.

Ejemplo 8.12. En Ostle (1981) se presenta un experimento en BCA, en el cual se midió el rendimiento sobre la misma parcela en el año experimental (y) al aplicar tres variedades y se contó con la información sobre rendimiento de la parcela en un año preliminar bajo condiciones uniformes del ensayo (x). La información obtenida en este experimento se presenta en la tabla 8.18.

Tabla 8.18: Rendimiento de la parcela en tres variedades

Bloque		Variedad		
		A	B	C
1	X	54	51	57
	Y	64	65	72
2	X	62	58	60
	Y	68	69	70
3	X	51	47	46
	Y	54	60	57
4	X	53	50	41
	Y	62	66	61

Las sumas de cuadrados y productos cruzados para el total son:

$$t_{xx} = \sum_{ij} x_{ij}^2 - \frac{x_{..}^2}{12} = (54^2 + \dots + 41^2) - \frac{630^2}{12} = 415$$

$$t_{yy} = \sum_{ij} y_{ij}^2 - \frac{y_{..}^2}{12} = (64^2 + \dots + 61^2) - \frac{768^2}{12} = 324$$

$$t_{xy} = \sum_{ij} x_{ij}y_{ij} - \frac{x_{..}y_{..}}{12} = (54)(64) + \dots + (41)(61) - \frac{(630)(768)}{12} = 256.$$

Las sumas de cuadrados y productos cruzados para bloques son:

$$B_{xx} = \sum_{j=1}^4 \frac{x_{.j}^2}{3} - \frac{x_{..}^2}{12} = \frac{1}{3}(162^2 + 180^2 + 144^2 + 144^2) - \frac{1}{12}(630)^2 = 297$$

$$B_{yy} = \sum_{j=1}^4 \frac{y_{.j}^2}{3} - \frac{y_{..}^2}{12} = \frac{1}{3}(201^2 + 207^2 + 171^2 + 189^2) - \frac{1}{12}(768)^2 = 252$$

$$\begin{aligned} B_{xy} &= \sum_{j=1}^4 \frac{x_{.j}y_{.j}}{3} - \frac{x_{..}y_{..}}{12} \\ &= \frac{1}{3}[(162)(201) + (180)(207) + (144)(171) + (144)(189)] - \frac{1}{12}(630)(768) \\ &= 234. \end{aligned}$$

Las sumas de cuadrados y productos cruzados para tratamientos son:

$$T_{xx} = \sum_{i=1}^3 \frac{x_i^2}{4} - \frac{x_{..}^2}{12} = \frac{1}{4}(220^2 + 206^2 + 204^2) - \frac{1}{12}(630)^2 = 38$$

$$\begin{aligned}
 T_{yy} &= \sum_{i=1}^3 \frac{y_{i.}^2}{4} - \frac{y_{..}^2}{12} = \frac{1}{4}(248^2 + 260^2 + 260^2) - \frac{1}{12}(768)^2 = 24 \\
 T_{xy} &= \sum_{i=1}^3 \frac{x_i y_{i.}}{4} - \frac{x_{..} y_{..}}{12} \\
 &= \frac{1}{4}[(220)(248) + (206)(260) + (204)(260)] - \frac{1}{12}(630)(768) \\
 &= -30.
 \end{aligned}$$

Las sumas de cuadrados y productos para el error son:

$$\begin{aligned}
 E_{xx} &= t_{xx} - B_{xx} - T_{xx} = 415 - 297 - 38 = 80 \\
 E_{yy} &= t_{yy} - B_{yy} - T_{yy} = 324 - 252 - 24 = 48 \\
 E_{xy} &= t_{xy} - B_{xy} - T_{xy} = 256 - 234 + 30 = 52.
 \end{aligned}$$

Con base en los anteriores resultados, se obtienen los siguientes estimadores de los parámetros

$$\begin{aligned}
 \hat{\mu} &= \bar{y}_{..} = 64 \\
 \hat{\beta} &= \frac{E_{xy}}{E_{xx}} = \frac{52}{80} = 0.65 \\
 \hat{\tau}_1 &= (62 - 64) - 0.65(55 - 52.5) = -3.63 \\
 \hat{\tau}_2 &= (65 - 64) - 0.65(51.5 - 52.5) = 1.65 \\
 \hat{\tau}_3 &= (65 - 64) - 0.65(51 - 52.5) = 1.98.
 \end{aligned}$$

Como $E_A = E_{yy} - \frac{E_{xy}^2}{E_{xx}} = 48 - \frac{52^2}{80} = 14.2$, entonces el estimador de la varianza poblacional σ^2 es $\hat{\sigma}^2 = \frac{1}{3}E_A = 2.84$.

Además,

$$S_A = S_{yy} - \frac{S_{xy}^2}{S_{xx}} = 72 - \frac{22^2}{118} = 67.89,$$

entonces el cuadrado medio de los tratamientos ajustado por covariable es:

$$CMT_{A(\text{ajustado})} = \frac{S_A - E_A}{t - 1} = \frac{67.89 - 14.2}{2} = 26.85.$$

A partir de los resultados anteriores, se obtiene la tabla 8.19 para llevar a cabo tanto un análisis de varianza para la variable Y, antes del ajuste, como un análisis de varianza para X.

Si se tiene interés en la hipótesis de no diferencia entre los efectos verdaderos de las tres variedades, se hace uso del siguiente estadístico:

$$F = \frac{CMT_{A(\text{ajustado})}}{CME_A} = \frac{26.85}{2.84} = 9.45.$$

Tabla 8.19: Análisis de covarianza para el rendimiento de la parcela al ensayar tres variedades.

C de V	gl	Sumas de cuadrados			gl	Sumas de cuadrados ajustadas por la regresión		
		$\sum x^2$	$\sum xy$	$\sum y^2$		SC	CM	F_c
Total	11	415	256	324				
Bloques (B)	3	297	234	252				
Variedades (T)	2	38	-30	24				
Error (E)	6	80	52	48	5	14.20	2.84	
$S = T + E$	8	118	22	72	7	67.89		
Trats(Ajustado)					2	53.70	26.85	9.45

Como este valor es mayor que $F_{(2,5,0.05)} = 5.78$ se rechaza H_0 y se concluye que hay diferencia entre las variedades y estas están influenciadas por el rendimiento de la cosecha anterior.

Para contrastar la hipótesis $H_0 : \beta = 0$, se hace uso del estadístico de prueba

$$F = \frac{E_{xy}^2/E_{xx}}{CME_A} = \frac{(52)^2/80}{2.84} = 11.90,$$

ya que este valor es mayor que $F_{(1,5,0.05)} = 6.61$, se rechaza la hipótesis nula. Por lo tanto, existe relación lineal entre el rendimiento de la parcela en el año experimental con el rendimiento de la misma en un año preliminar, y en este sentido, el ajuste proporcionado por el análisis de covarianza es necesario.

8.4.4. Análisis general de covariables

En la discusión hasta ahora se ha considerado el caso más simple, pero al mismo tiempo el más importante, que es considerar ensayos donde se incluye una sola covariable (x) y se asume, además, la relación lineal de esta con las observaciones (y) a través de los tratamientos. Sin embargo, pueden existir situaciones en que la relación entre x y y tiene forma polinomial o también se pueden considerar más covariables $x_1, x_2, \dots, x_d$, las cuales tienen una relación lineal o polinomial con y .

La anterior problemática se soluciona usando el modelo general de covarianza para un vector Y de observaciones $n \times 1$, el cual se puede expresar como:

$$Y = X\theta + Z\eta + e, \quad (8.22)$$

donde $X\theta$ representa la parte asociada con las variables de clasificación y $Z\eta$ representa la parte asociada con las covariables involucradas en el modelo, X y Z son matrices de constantes conocidas de dimensiones $n \times p$ y $n \times d$,

respectivamente, θ y η son vectores de parámetros desconocidos de tamaños $p \times 1$ y $d \times 1$, respectivamente, y e es un vector de errores $n \times 1$, con $E(e) = \mathbf{0}$, y $Var(e) = \sigma^2 I$.

Si se excluyen las covariables o si $\eta = \mathbf{0}$, entonces el modelo (8.22) se reduce a:

$$Y = X\theta + e^*. \quad (8.23)$$

Para este modelo, la descomposición ortogonal de Y está dada por:

$$Y = X(X^t X)^{-1} X^t Y + [I - X(X^t X)^{-1} X^t]Y = P_X Y + (I - P_X)Y$$

donde $P_X = X(X^t X)^{-1} X^t$ y además, como se mostró en el capítulo 3, tanto P_X y $I - P_X$ son matrices idempotentes. En (8.23), $(I - P_X)Y$ es el vector de residuales y $Y^t(I - P_X)Y$ es la suma de cuadrados del residual.

El modelo (8.22) se puede reescribir como:

$$\begin{aligned} Y &= X\theta_0 + (I - P_X)Z\eta + e \\ &= X[\theta_0 - (X^t X)^{-1} X^t Z\eta] + Z\eta + e. \end{aligned}$$

De este modo, $\theta = \theta_0 - (X^t X)^{-1} X^t Z\eta$.

Utilizando la expresión anterior, se obtiene el siguiente sistema de ecuaciones normales

$$\begin{pmatrix} X^t X & X^t(I - P_X)Z \\ Z^t(I - P_X)X & Z^t(I - P_X)Z \end{pmatrix} \begin{pmatrix} \hat{\theta}_0 \\ \hat{\eta} \end{pmatrix} = \begin{pmatrix} X^t Y \\ Z^t(I - P_X)Y \end{pmatrix},$$

la cual se reduce a

$$\begin{pmatrix} X^t X & \mathbf{0} \\ \mathbf{0} & Z^t(I - P_X)Z \end{pmatrix} \begin{pmatrix} \hat{\theta}_0 \\ \hat{\eta} \end{pmatrix} = \begin{pmatrix} X^t Y \\ Z^t(I - P_X)Y \end{pmatrix}$$

Del sistema anterior, se obtienen las siguientes estimaciones:

$$\hat{\theta}_0 = (X^t X)^{-1} X^t Y, \quad (8.24)$$

es decir, el estimador de θ bajo el modelo (8.23), y

$$\hat{\eta} = [Z^t(I - P_X)Z]^{-1} Z^t(I - P_X)Y. \quad (8.25)$$

De donde se sigue que

$$\hat{\theta} = \hat{\theta}_0 - (X^t X)^{-1} X^t Z\hat{\eta}. \quad (8.26)$$

Las varianzas de los anteriores estimadores son:

$$Var(\hat{\theta}_0) = (X^t X)^{-1} \sigma^2$$

y

$$Var(\hat{\eta}) = [Z^t(I - P_X)Z]^{-1}\sigma^2.$$

Como $\hat{\theta}_0$ y $\hat{\eta}$ no son correlacionados, entonces

$$Var(\hat{\theta}) = [(X^tX)^{-1} + (Z^t(I - P_X)Z)^{-1}]\sigma^2.$$

En la solución (8.25), los elementos de $Z^t(I - P_X)Z$ corresponden a la suma de cuadrados del error (elementos de la diagonal) y la suma del error de los productos (elementos fuera de la diagonal) en el modelo (8.23), cuando las columnas de Z se toman como un vector de “observaciones”. Análogamente, los elementos del vector $Z^t(I - P_X)Y$ son las correspondientes sumas del error de los productos usando alternativamente las columnas de Z con el vector de observaciones Y ; con esto, se tiene una forma fácil de obtener $\hat{\eta}$ y $\hat{\theta}_0$.

La suma de cuadrados del error se obtiene de forma usual como:

$$SCE = Y^tY - \hat{\theta}_0X^tY - \hat{\eta}Z^t(I - P_X)Y \quad (8.27)$$

La anterior expresión, también se puede expresar como:

$$SCE = SCE_{MR} - \hat{\eta}Z^t(I - P_X)Y,$$

donde SCE_{MR} corresponde a la suma de cuadrados del error asociada al modelo (8.23). En esta última expresión, se comprueba que SCE a través del modelo (8.22) es más pequeña que la SCE para el modelo (8.23), y la reducción es de $\hat{\eta}Z^t(I - P_X)Y$.

De (8.27), se encuentra la siguiente estimación para σ^2 ,

$$\hat{\sigma}^2 = \frac{SCE}{n - p - d} = CME$$

Finalmente, para contrastar alguna hipótesis sobre θ o subvectores de θ , según una apropiada partición,

$$\theta = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}.$$

Para $H_0 : \theta_1 = \theta^*$, se ajusta el modelo

$$Y = X^* \begin{pmatrix} \theta^* \\ \theta_2 \end{pmatrix} + Z\eta + e.$$

A partir de este modelo se encuentra la suma de cuadrados del error SCE^* , realizando el mismo procedimiento presentado anteriormente.

Suponga que en H_0 se tienen s contrastes de hipótesis de interés, entonces el estadístico de prueba es:

$$F = \frac{(SCE^* - SCE)/s}{CME}.$$

Si este valor es mayor que $F_{(s, n-p-d, \alpha)}$, se rechaza la hipótesis nula ($H_0 : \theta_1 = \theta^*$).

Adicionalmente, si se quiere contrastar $H_0 : \eta = \mathbf{0}$ para esta hipótesis, se hace uso del estadístico de prueba

$$F = \frac{R(\eta/\theta)/d}{CME},$$

donde $R(\eta/\theta) = R(\theta, \eta) - R(\theta)$, con $R(\theta, \eta)$ la suma de cuadrados asociada al modelo obtenida a partir de (8.22) y $R(\theta)$ la suma de cuadrados del modelo obtenida a partir de (8.23). En este caso, si $F > F_{(d, n-p-d, \alpha)}$, se rechaza la hipótesis $H_0 : \eta = \mathbf{0}$, encontrando asociación entre las covariables y la variable respuesta a través de los diferentes factores de clasificación.

8.5. Implementación en SAS

A partir de los datos de los ejemplos 8.3, 8.8, 8.9 y 8.12 desarrollados a lo largo del capítulo, se presentan a continuación los programas en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos.

```
/* Diseño en Cuadrado Latino*/
DATA EJEMPL083; /*archivo del ejemplo 8.3*/
INPUT DIA LOTE METODO RESISTENCIA @@;
CARDS;
1 1 1 303 1 2 2 299 1 3 3 290 1 4 4 290 2 1 2 280 2 2 1 321
2 3 4 313 2 4 3 282 3 1 3 275 3 2 4 315 3 3 1 319 3 4 2 300
4 1 4 304 4 2 3 293 4 3 2 295 4 4 1 305
;

PROC GLM DATA=EJEMPL083;
CLASS DIA LOTE METODO;
MODEL RESISTENCIA=DIA LOTE METODO;
MEANS METODO/LSD SCHEFFE;
RUN;

/* Diseño en series de Cuadrados Latinos */
DATA EJEMPL087;
DO SEMANAS = 1 TO 2;
```

```

DO DIAS= 1 TO 4;
DO SUPERMERCADOS = 1 TO 4;
INPUT TRAT $ Y @; OUTPUT;
PUT SEMANAS DIAS TIENDAS;
END;
INPUT;
END;
END;
CARDS;
A 14 B 8 C 40 D 48
B 20 A 22 D 48 C 25
D 24 C 12 B 12 A 27
C 31 D 16 A 32 B 22
B 24 D 30 C 24 A 12
D 42 A 4 B 12 C 32
A 8 C 8 D 36 B 28
C 28 B 32 A 48 D 54
;
PROC PRINT DATA=EJEMPLO87;
RUN;

TITLE1 "ANÁLISIS PRIMERA SEMANA";
DATA CL1;
SET EJEMPLO87;
IF SEMANAS = 1;
PROC PRINT DATA=CL1; RUN;

PROC GLM DATA=CL1;
CLASS DIAS TRAT SUPERMERCADOS;
MODEL Y = DIAS SUPERMERCADOS TRAT/SS1;
RUN;

TITLE2 "ANÁLISIS SEGUNDA SEMANA";
DATA CL2;
SET EJEMPLO87;
IF SEMANAS = 2;

PROC PRINT DATA=CL2; RUN;

PROC GLM DATA=CL2;
CLASS DIAS TRAT SUPERMERCADOS;
MODEL Y = DIAS SUPERMERCADOS TRAT/SS1;
RUN;

PROC GLM DATA=EJEMPLO87;
CLASS DIAS TRAT SUPERMERCADOS SEMANAS;
MODEL Y = SEMANAS DIAS(SEMANAS) SUPERMERCADOS(SEMANAS) TRAT/SS1;
RUN;

```

```

/* Usando el modelo de la ecuación (8.5) */

PROC GLM DATA=EJEMPL087;
CLASS DIAS TRAT SUPERMERCADOS SEMANAS;
MODEL Y = SUPERMERCADOS*SEMANAS DIAS TRAT/SS1;
RUN;

/* Diseño en cuadrado greco-latino*/

DATA EJEMPL088;
INPUT DIA LOTE METODO MAQUINA RESISTENCIA @@;
CARDS;
1 1 1 1 303 1 2 2 2 299 1 3 3 3 290 1 4 4 4 290
2 1 2 4 280 2 2 1 3 321 2 3 4 2 313 2 4 3 1 282
3 1 3 2 275 3 2 4 1 315 3 3 1 4 319 3 4 2 3 300
4 1 4 3 304 4 2 3 4 293 4 3 2 1 295 4 4 1 2 305
;

PROC GLM DATA=EJEMPL088;
CLASS DIA LOTE METODO MAQUINA;
MODEL RESISTENCIA=DIA LOTE METODO MAQUINA;
MEANS METODO/LSD SCHEFFE;
RUN;

/* Diseño completamente aleatorizado con covariable */

DATA EJEMPL089;
INPUT RAPIDEZ X Y @@;
CARDS;
1000 70 72 1200 90 70 1400 115 76
1000 72 76 1200 93 76 1400 110 73
1000 75 72 1200 95 68 1400 118 72
1000 76 76 1200 96 76 1400 122 82
1000 80 82 1200 97 78 1400 125 78
1000 81 76 1200 102 78 1400 125 87
1000 85 80 1200 105 76 1400 130 85
1000 83 78 1200 108 86 1400 133 88
1000 91 86 1200 110 80 1400 135 82
1000 92 86 1200 115 86 1400 119 81
1000 98 96 1200 117 85 1400 140 88
1000 100 90 1200 120 90 1400 140 92
;

/* Pendientes no constantes */
PROC GLM DATA=EJEMPL089;
CLASS RAPIDEZ;
MODEL Y=RAPIDEZ X(RAPIDEZ)/SS1 SS2 SOLUTION;
LSMEANS RAPIDEZ/STDERR PDIFF COV OUT=ADJMEANS;
RUN;

```



```

/* EJEMPLO 8.10*/
/* Pendiente constante */
PROC GLM DATA=EJEMPLO89;
CLASS RAPIDEZ;
MODEL Y=RAPIDEZ X/SS1 SS2 SOLUTION;
LSMEANS RAPIDEZ/STDERR PDIF COV OUT=ADJMEANS;
RUN;

/* Diseño en bloques completamente aleatorizado con covariable */

DATA EJEMPLO812;
INPUT BLOQUE VARIEDAD $ RENDIMIENTO1 RENDIMIENTO2 @@;
CARDS;
1 A 54 64 1 B 51 65 1 C 57 72
2 A 62 68 2 B 58 69 2 C 60 70
3 A 51 54 3 B 47 60 3 C 46 57
4 A 53 62 4 B 50 66 4 C 41 61
;
PROC GLM DATA=EJEMPLO812;
CLASS BLOQUE VARIEDAD;
MODEL RENDIMIENTO2=BLOQUE VARIEDAD RENDIMIENTO1/SS1 SS3 SOLUTION;
RUN;

```

8.6. Implementación en R

A partir de los datos de los ejemplos [8.3](#), [8.7](#), [8.8](#), [8.9](#) y [8.12](#), se presentan a continuación los programas en el software estadístico R.

```

#####
## Ejemplo 8.3 ##
#####

#Introducción de los datos del ejemplo
ejemplo8.3 <- data.frame(dia=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4))),
lote=factor(rep(c(1,2,3,4),4)),
metodo=factor(c(1,2,3,4,2,1,4,3,3,4,1,2,4,3,2,1)),
resistencia=c(303,299,290,290,280,321,313,282,275,
315,319,300,304,293,295,305))

anova8.3 <- lm(resistencia ~ dia+lote+metodo,contrasts=list(dia="contr.sum",
lote="contr.sum",metodo="contr.sum"),data=ejemplo8.3)
summary(anova8.3)
summary(aov(anova8.3))
boxplot(resistencia ~ metodo, data=ejemplo8.3)

library(agricolae)
# Prueba LSD de Fisher

```

```

LSD.test(anova8.3,"metodo", group=TRUE,console=TRUE,main="Metodo")
# Prueba de Scheffe
scheffe.test(anova8.3,"metodo",group=TRUE,console=TRUE,main="Metodo")
# Prueba de Tukey para comparaciones múltiples y el gráfico correspondiente
TukeyHSD(aov(anova8.3),which="metodo",ordered=TRUE)
plot(TukeyHSD(aov(anova8.3),which="metodo",ordered=TRUE))

#####
## Ejemplo 8.4 ##
#####

## Estimación de un dato faltante

CL.matriz<-t(matrix(ejemplo8.3$resistencia,4,4))
CL.matriz[CL.matriz==315]<-NA
CL.matriz

xFalt<-315
t<-4
Cv<-sum(CL.matriz[,2],na.rm=T)
Cv
Ru<-sum(CL.matriz[3,],na.rm=T)
Ru
G<-sum(CL.matriz[,],na.rm=T)
sum.Trat<-aggregate(resistencia~metodo, FUN=sum,data=ejemplo8.3)
C.sum<-sum.Trat[4,2]
Tw<-C.sum-xFalt
Tw
x.est<-((t*(Ru+Cv+Tw))-(2*G))/((t-2)*(t-1))
x.est

#####
## Ejemplo 8.5 ##
#####

CMdias<-30.5
CMLotes<-248.5
CME<-44.5
t<-4

# Eficiencia relativa comparada a DCA
ERDCA<-(CMdias+CMLotes+(t-2)*CME)/(t*CME)
ERDCA

# Eficiencia relativa comparada con un DBCA
ERDBCA<-(CMdias+(t-2)*CME)/((t-1)*CME)
ERDBCA

```

```
#####
## Ejemplo 8.7 ##
#####

# series de Cuadrados Latinos #

ejemplo8.7 <- data.frame(dias=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4),
rep(1,4),rep(2,4),rep(3,4),rep(4,4))),supermercado=factor(rep(c(1,2,3,4),8)),
tratamientos=factor(c(1,2,3,4,2,1,4,3,4,3,2,1,3,4,1,2,2,4,3,1,4,1,2,3,1,
3,4,2,3,2,1,4)),semanas=factor(c(rep(1,16),rep(2,16))), peso=c(14,8,40,48,
20,22,48,25,24,12,12,27,31,16,32,22,24,30,24,12,42,4,12,32,8,8,36,28,28,32,
48,54))

anova8.7<-aov(peso~semanas+dias%in%semanas+supermercado%in%semanas+
tratamientos,data=ejemplo8.7)
summary(anova8.7)          # Construye la tabla de análisis de varianza

# Prueba LSD de Fisher
LSD.test(anova8.7,"tratamientos",group=TRUE,console=TRUE,main=
"Tratamiento")
# Prueba de Scheffe
scheffe.test(anova8.7,"tratamientos",group=TRUE,console=TRUE,main=
"Tratamiento")
# Prueba de Tukey para comparaciones múltiples y el gráfico correspondiente
TukeyHSD(anova8.7,which="tratamientos",ordered=TRUE)
plot(TukeyHSD(anova8.7,which="tratamientos",ordered=TRUE))

# Otra alternativa, incluyendo solo el supermercado cuando estos son
# diferentes
anova8.7_1<-aov(peso~supermercado:semanas+dias+tratamientos,data=ejemplo8.7)
anova(anova8.7_1)

# Prueba LSD de Fisher
LSD.test(anova8.7_1,"tratamientos",group=TRUE,console=TRUE,main=
"Tratamiento")
# Prueba de Scheffe
scheffe.test(anova8.7_1,"tratamientos",group=TRUE,console=TRUE,main=
"Tratamiento")
# Prueba de Tukey para comparaciones múltiples y el gráfico correspondiente
TukeyHSD(anova8.7_1,which="tratamientos",ordered=TRUE)
plot(TukeyHSD(anova8.7_1,which="tratamientos",ordered=TRUE))

#####
## Ejemplo 8.8 ##
#####

#Introducción de los datos del ejemplo
ejemplo8.8 <- data.frame(dia=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4))),
lote=factor(rep(c(1,2,3,4),4)),
```

```

metodo=factor(c(1,2,3,4,2,1,4,3,3,4,1,2,4,3,2,1)),
maquina=factor(c(1,2,3,4,4,3,2,1,2,1,4,3,3,4,1,2)),
resistencia=c(303,299,290,290,280,321,313,282,275,
315,319,300,304,293,295,305))

anova8.8 <- lm(resistencia ~ dia+lote+metodo+maquina,contrasts=list(dia=
"contr.sum",lote="contr.sum",metodo="contr.sum",maquina="contr.sum"),
data=ejemplo8.8)
summary(anova8.8)
summary(aov(anova8.8))

# Prueba LSD de Fisher
LSD.test(anova8.8,"metodo", group=TRUE,console=TRUE,main="Máquina")

# Prueba de Scheffe
scheffe.test(anova8.8,"metodo",group=TRUE,console=TRUE,main="Máquina")

# Prueba de Tukey para comparaciones múltiples y el gráfico correspondiente
TukeyHSD(aov(anova8.8),which="metodo",ordered=TRUE)
plot(TukeyHSD(aov(anova8.8),which="metodo",ordered=TRUE))

#####
## Ejemplos 8.9 y 8.10 ##
#####

#Introducción de los datos del ejemplo
ejemplo8.9<-data.frame(rapidez=factor(c(rep(1000,12),rep(1200,12),
rep(1400,12))), dureza=c(70,72,75,76,80,81,85,83,91,92,98,100,90,93,95,
96,97,102,105,108,110,115,117,120,115,110,118,122,125,125,130,133,135,
119,140,140), cantidad=c(72,76,72,76,82,76,80,78,86,86,96,90,70,76,
68,76,78,78,76,86,80,86,85,90,76,73,72,82,78,87,85,88,82,81,88,92))

# análisis de varianza
anova8.9 <- aov(cantidad~rapidez,data=ejemplo8.9) # suma de cuadrados en y
summary(anova8.9)

# Gráfico para ver igualdad de pendientes a una constante
plot(cantidad ~ dureza,xlab='cantidad de metal eliminado',ylab='Dureza',
data=ejemplo8.9)
rap1000<-lm(cantidad~dureza,data=ejemplo8.9[ejemplo8.9$rapidez=='1000',])
rap1200<-lm(cantidad~dureza,data=ejemplo8.9[ejemplo8.9$rapidez=='1200',])
rap1400<-lm(cantidad~dureza,data=ejemplo8.9[ejemplo8.9$rapidez=='1400',])
abline(rap1000,col=1)
abline(rap1200,col=2)
abline(rap1400,col=3)
legend("topleft",c('1000','1200','1400'),col=1:3,lty=1)

library(lattice)
xyplot(cantidad ~ dureza, groups=rapidez, type="p", pch=16,

```

```

par.settings=simpleTheme(pch=16), scales=list(x=list(relation='same'),
y=list(relation='same')), data=ejemplo8.9)
abline(rap1000,col='blue')
abline(rap1200,col=2)
abline(rap1400,col=1)
legend("topleft",c('1000','1200','1400'),col=c('blue',2,1),lty=1)

# Modelo ajustado con pendientes diferentes
lm1 <- lm(cantidad ~ rapidez*I(dureza-mean(dureza)),contrasts=list(
rapidez="contr.sum"),data=ejemplo8.9)
summary(lm1)

# Modelo ajustado con pendientes diferentes, resultados del libro
lm2<-lm(cantidad~rapidez+I(dureza-mean(dureza))%in%rapidez,contrasts=list(
rapidez="contr.sum"),data=ejemplo8.9)
summary(lm2)
anova(lm2)

# Modelos ajustado con pendiente constante
lm3 <- lm(cantidad ~ rapidez+I(dureza-mean(dureza)),contrasts=list(
rapidez="contr.sum"),data=ejemplo8.9)
summary(lm3)
# Prueba de igualdad de betas a una constante
anova(lm3,lm2)

library(car)
# Sumas de cuadrados tipos II y III para significancia de los tratamientos
Anova(lm3, type="II")
Anova(lm3, type="III", singular.ok=T)

#####
## Ejemplo 8.12 ##
#####

#Introducción de los datos del ejemplo
ejemplo8.12<-data.frame(bloque=factor(c(rep(1,3),rep(2,3),rep(3,3),
rep(4,3))),variedad=factor(rep(c(1,2,3),4)),rendimiento.x=c(54,51,57,62,
58,60,51,47,46,53,50,41),rendimiento.y=c(64,65,72,68,69,70,54,60,57,
62,66,61))

# Modelo ajustado con pendientes diferentes
lm4<-lm(rendimiento.y~bloque+variedad*I(rendimiento.x-mean(rendimiento.x)),
data=ejemplo8.12) #suma de cuadrados en y
summary(lm4)

# Modelo ajustado con pendientes diferentes
lm5<-lm(rendimiento.y~bloque+variedad+I(rendimiento.x-mean(rendimiento.x))
%in%variedad,data=ejemplo8.12) # suma de cuadrados en y

```

```
summary(lm5)
anova(lm5)

# Modelos ajustado con pendiente constante
lm6<-lm(rendimiento.y~bloque+variedad+I(rendimiento.x-mean(rendimiento.x)),
data=ejemplo8.12) # suma de cuadrados en y
summary(lm6)
# Prueba de igualdad de betas a una constante
anova(lm6,lm5)

# Sumas de cuadrados tipos II y III para tratamientos significativos
Anova(lm6, type="II")
Anova(lm6, type="III", singular.ok=T)
```

8.7. Ejercicios

1. Los siguientes datos tomados de Martínez (1972), hacen referencia a los rendimientos de caña de azúcar por parcela de 134.4m^2 de un Diseño en Cuadrado Latino 6×6 en el que se ensayaron 6 tratamientos que comprenden combinaciones de elementos menores.

	1	2	3	4	5	6
1	6	5	2	1	4	3
	1626	1639	1617	1062	1501	1827
2	4	1	6	5	3	2
	1816	1103	1926	1992	1682	1498
3	3	4	5	6	2	1
	1936	2134	1881	1797	1701	824
4	2	6	4	3	1	5
	1933	1995	2011	1886	812	1596
5	1	2	3	4	5	6
	1262	2142	2229	2066	2066	1898
6	5	3	1	2	6	4
	1624	1885	1089	1879	1343	1245

- a. Escriba el modelo lineal para este experimento y explique los términos.
- b. Lleve a cabo el análisis de varianza para determinar si hay diferencias significativas entre rendimientos por tratamiento y concluya.
- c. Realice la prueba de comparación múltiple de Tukey y concluya.
- d. Verifique si se satisfacen los supuestos del modelo propuesto.
- e. Si fuese a recomendar un tratamiento para seguir aplicando, ¿cuál recomendaría y por qué?

2. La siguiente tabla de análisis de varianza hace referencia al rendimiento de trigo en kg/parcela cuando se ensayan 4 variedades.

C de V	gl	SC	CM	F	Valor p
Filas				1.44	0.3213
Columnas				5.04	0.0444
Tratamientos				58.47	0.0000
Error		2.72			
Total		90.40			

Complete la tabla, interprete y concluya.

3. Escriba la tabla de análisis de varianza con submuestreo para un Diseño Cuadro Latino, presente el modelo y estime todos los componentes de la tabla ANOVA.
4. Cuatro fertilizantes A, B, C y D se contrastan en un experimento de campo. Los resultados de la producción en una cosecha se indican a continuación:

A17	B13	C19	D16
B13	C20	D14	A18
C21	D16	A15	B12
D14	A16	B14	C18

Lleve a cabo el análisis de varianza apropiado para este arreglo y concluya. Plantee algunas pruebas ortogonales de interés y comente en detalle su conclusión.


5. Suponga un cuadro latino 4×4 en el que se perdió una unidad experimental, la información observada se presenta en la siguiente tabla:

	C_1	C_2	C_3	C_4
F_1	x	y_{123}	y_{131}	y_{142}
F_2	y_{211}	y_{224}	y_{232}	y_{243}
F_3	y_{313}	y_{322}	y_{334}	y_{341}
F_4	y_{412}	y_{421}	y_{433}	y_{444}

Los dos primeros subíndices están asociados a los efectos controlados y el tercer subíndice hace referencia al efecto de los tratamientos. Para esta información:

- a. Lleve a cabo el análisis de varianza estimando la observación faltante.

- b. Estructure la matriz de diseño para este arreglo.
 - c. ¿Cómo sería el análisis de varianza cuando no se lleva a cabo la estimación de este dato faltante?
 - d. Ubique un experimento con datos reales que satisfaga la estructura anterior, admita que se ha perdido la información asociada con esa combinación específica y desarrolle nuevamente a., b. y c.
6. Considere un experimento con los siguientes factores: 3 estaciones (*s*), 5 cámaras (*c*), 4 suelos (*l*), 4 fertilizantes (*f*) y 4 variedades (*v*). Los datos fueron recolectados según el siguiente diagrama.



- a. Considere a cada cámara como un Cuadrado Latino con filas=*f*, columnas=*l*, tratamientos=*v*. Presente la tabla de ANOVA con fuentes de variación y grados de libertad.
- b. Suponga que solo se obtuvo el cuadro latino asociado con la primera cámara y que se perdió la observación con (*), proponga una estimación para este valor faltante.

Fertilizante	Suelos			
	1	2	3	4
1	D 10.7	A 10.3	B 11.2	C 10.9
2	A 11.3	B 10.5 (*)	C 12.0	D 11.5
3	B 11.8	C 10.9	D 10.5	A 11.3
4	C 14.1	D 11.6	A 11.0	B 11.7

7. Los datos que se presentan a continuación corresponden a la producción (en toneladas por hectárea) de tres híbridos de maíz (A, B y D) y una variedad de control (C) para un experimento que se diseñó como un Cuadrado Latino. Se hizo doble control local: por filas, la pendiente del terreno, por columnas, los cuatro niveles de riego diferentes.

Pendientes	Niveles de riego			
	1	2	3	4
1	B 1.640	D 1.210	C 1.425	A 1.345
2	C 1.475	A 1.185	D 1.400	B 1.290
3	A 1.670	C 0.710	B 1.665	D 1.180
4	D 1.565	B 1.290	A 1.655	C 0.660

- Escriba el modelo lineal para este experimento y explique los términos asociados al modelo.
 - Presente el análisis de varianza para determinar si hay diferencias significativas entre rendimientos por tratamiento y lleve a cabo la hipótesis sobre interacción.
 - Realice la prueba de comparación múltiple y concluya.
 - Verifique si se satisfacen los supuestos del modelo propuesto.
 - Si fuese a recomendar un tratamiento para seguir aplicando, ¿cuál recomendaría y por qué?
8. Suponga que un ingeniero está interesado en comparar tres procesos químicos para la manufactura de cierto compuesto. Se sospecha que la impureza de la materia prima usada en el proceso puede afectar el producto final, sin embargo, se espera ajustar el proceso al final del análisis. Usando un DCA con 15 unidades experimentales se obtuvo la siguiente información:

Tratamiento A		Tratamiento B		Tratamiento C	
Cantidad de impureza (X)	Producción (Y)	Cantidad de impureza (X)	Producción (Y)	Cantidad de impureza (X)	Producción (Y)
4.1	12.5	6.8	11.5	6.6	6.8
2.9	10.3	2.7	8.6	2.2	4.8
1.5	9.6	3.8	7.2	3.5	5.6
4.1	12.6	6.4	11.6	3.5	7.5
2.2	11.3	5.6	8.9	4.6	6.2

- Grafique los datos e interpréte los.
 - Estime la recta de regresión para cada tratamiento.
 - Pruebe la hipótesis que las tres pendientes en b. son iguales.
 - Obtenga una estimación de las medias sin ajustar y ajustadas de los tratamientos y compárelas comentando los resultados respectivos.
 - Realice e interprete la tabla de análisis de varianza.
9. Muestre que $\hat{\beta}$ presentado en (8.12) es un promedio ponderado de los $\hat{\beta}_i$ individuales, donde las ponderaciones son el recíproco de $var(\hat{\beta}_i)$, $i = 1, \dots, t$.

10. Para un DCL presente la tabla de análisis de varianza caracterizando cada una de las componentes, cuando se tiene una covariable.
11. Con los resultados teóricos del punto anterior, lleve a cabo el análisis para los siguientes datos provenientes del peso de 16 novillos teniendo el peso inicial (X). Dichos pesos fueron usados en un experimento para comparar cuatro diferentes hormonas (A, B, C y D). Los novillos se agruparon en cuatro bloques de acuerdo con características especiales como raza y tipo de alimento inicial. Después de aplicar los tratamientos, el peso del riñón (en gramos) fue medido en los animales muertos, los resultados fueron los siguientes:

Bloque	A		B		C		D		Total	
	X	Y	X	Y	X	Y	X	Y	X	Y
I	560	133	440	128	530	129	690	134	2220	524
II	470	132	440	127	510	130	420	125	1840	514
III	410	127	360	127	380	124	430	126	1580	504
IV	500	132	460	128	500	129	540	131	2000	520
Total	1940	524	1700	510	1920	512	2080	516	7640	2062

Lleve a cabo el análisis estadístico si se ajustaron los siguientes modelos:

$$y_{ij} = b_i + \epsilon_{ij}$$

$$y_{ij} = b_i + \tau_j + \epsilon_{ij}$$

$$y_{ij} = b_i + \tau_j + \theta x_{ij} + \epsilon_{ij}$$

$$y_{ij} = b_i + \theta x_{ij} + \epsilon_{ij},$$

con $i = 1, 2, 3, 4$ y $j = 1, 2, 3, 4$. ¿El peso inicial de los novillos afecta el peso del riñón? Comente en detalle su conclusión.

12. El rendimiento de tres variedades de trigo en una cosecha experimental se presenta en la siguiente tabla:

Bloque		Variedades		
		A	B	C
1	X	54	51	57
	Y	64	65	72
2	X	62	64	60
	Y	68	69	70
3	X	51	47	46
	Y	54	60	57

X hace referencia al rendimiento de una parcela en un año preliminar bajo condiciones uniformes de ensayo y Y hace referencia al rendimiento de la misma parcela durante el año experimental, se ensayaron 3 variedades.

- a. Grafique los datos.
 - b. Estime la recta de regresión para cada tratamiento.
 - c. Pruebe la hipótesis según la cual las tres pendientes en b. son iguales.
 - d. Lleve a cabo el análisis de varianza de los datos e interprete los resultados.
 - e. Pruebe el contraste $H_0 : A = B$ vs $H_a : A < B$.
13. El siguiente ensayo ilustra el análisis de covarianza en un DBCA, en el que se ensayaron 12 tratamientos de fertilizantes en cuatro BCA (Martínez 1981). Las variables son:

REP: bloque completo.

TRAT: número de tratamientos.

N: dosis nitrógeno (kg/Ha).

P: dosis fósforo (kg/Ha).

K: dosis potasio (kg/Ha).

Y: rendimiento (Ton/Ha).

X: número de tallos por parcela.

```
DATA EJERCICIO;
INPUT REP TRAT N P K Y X @@;
N1 = N*N;
P1 = P*P;
K1 = K*K;
CARDS;
```

1	1	0	0	0	107.5	319	1	2	200	0	0	89.2	300
1	3	0	200	0	102.2	280	1	4	200	0	0	88.1	318
1	5	0	0	200	121.4	308	1	6	200	0	200	119.4	306
1	7	0	200	200	110.6	316	1	8	200	200	200	106.4	290
1	9	100	100	100	114.7	315	1	10	300	100	100	116.4	330
1	11	100	300	100	96.1	302	1	12	100	100	300	102.5	321
2	1	0	0	0	103.6	308	2	2	200	0	0	102.8	307
2	3	0	200	0	110.0	280	2	4	200	200	0	105.0	315
2	5	0	0	200	100.3	304	2	6	200	0	200	111.1	310
2	7	0	200	200	113.6	303	2	8	200	200	200	120.0	306
2	9	100	100	100	106.9	299	2	10	300	100	100	129.2	315
2	11	100	300	100	107.8	353	2	12	100	100	300	114.4	307
3	1	0	0	0	85.5	319	3	2	200	0	0	84.4	320
3	3	0	200	0	76.9	299	3	4	200	200	0	104.7	319
3	5	0	0	200	111.7	315	3	6	200	0	200	100.8	334
3	7	0	200	200	114.7	284	3	8	200	200	200	88.9	314
3	9	100	100	100	114.4	310	3	10	300	100	100	106.4	319
3	11	100	300	100	106.6	310	3	12	100	100	300	116.4	316
4	1	0	0	0	115.6	275	4	2	200	0	0	108.1	302
4	3	0	200	0	87.5	268	4	4	200	200	0	120.3	311

```

4 5 0 0 200 126.1 290 4 6 200 0 200 119.2 296
4 7 0 200 200 122.2 295 4 8 200 200 200 130.0 299
4 9 100 100 100 115.8 297 4 10 300 100 100 136.9 317
4 11 100 300 100 122.8 294 4 12 100 100 300 126.7 302
;

PROC GLM;
CLASS REP TRAT;
MODEL Y= REP TRAT X;
LSMEANS TRAT;

PROC GLM;
MODEL Y=N P N1 P1 N*P K;

PROC GLM;
MODEL Y=N P N1 P1 N*P;

PROC GLM;
MODEL Y=N N1;

PROC GLM;
MODEL Y=P P1;

PROC GLM;
MODEL Y=N;

PROC GLM;
MODEL Y=P;

PROC GLM;
MODEL Y=K;

PROC ANOVA;
CLASS REP TRAT;
MODEL Y=REP TRAT;
MEANS TRAT;
RUN;

```

Corra el anterior programa en SAS e interprete los resultados arrojados en cada una de las diferentes salidas.

8.8. Anexo

Por la importancia de la teoría de Galois en la construcción de Cuadrados Latinos ortogonales en este anexo, se describe brevemente esta estructura.

8.8.1. Campo de Galois

Sea t un número natural primo (con la finalidad de ilustrar se toma $t = 5$) y considérese además todos los números enteros (positivos, negativos o cero),

cuya división por t dé el mismo residuo. En el caso, $t = 5$ se obtienen solo 5 clases de números, cada una con infinitos elementos, a saber:

$$\alpha_0 = \{0, 5, 10, \dots, -5, -10, \dots\}$$

$$\alpha_1 = \{1, 6, 11, \dots, -4, -9, \dots\}$$

$$\alpha_2 = \{2, 7, 12, \dots, -3, -8, \dots\}$$

$$\alpha_3 = \{3, 8, 13, \dots, -2, -7, \dots\}$$

$$\alpha_4 = \{4, 9, 14, \dots, -1, -6, \dots\}.$$

Al operar esos 5 elementos:

$$\alpha_1 + \alpha_4 = \{1\} + \{4\} = \{5\} = \{0\} = \alpha_0$$

$$\alpha_2 * \alpha_3 = \{2\} * \{3\} = \{6\} = \{1\} = \alpha_1$$

$$\frac{\alpha_1}{\alpha_3} = \frac{\{1\}}{\{3\}} = \frac{\{6\}}{\{3\}} = \{2\} = \alpha_2$$

Esos 5 elementos forman un cuerpo finito o cuerpo de Galois. Este se puede sumar, restar, multiplicar y dividir (excepto por α_0) dos elementos cualesquiera, obteniendo siempre como resultado elementos de ese cuerpo.

Para $t = 3$ el cuerpo finito estará formado por los tres elementos siguientes:

$$\alpha_0 = \{0, 3, 6, \dots, -3, -6, \dots\}$$

$$\alpha_1 = \{1, 4, 7, \dots, -2, -5, \dots\}$$

$$\alpha_2 = \{2, 5, 8, \dots, -1, -4, \dots\}$$

Con estos elementos se pueden construir polinomios tales como:

$$\alpha_1 X + \alpha_2$$

$$\alpha_1 X^2 + \alpha_1 X + \alpha_2.$$

Si se considera un polinomio de segundo grado conveniente, por ejemplo $\beta_0 = \alpha_1 X^2 + \alpha_1 X + \alpha_2 = \{1\}X^2 + \{1\}X + \{2\}$, se tiene un polinomio de la misma clase de todos los polinomios cuya división por β_0 da el mismo residuo. De esta forma, se obtiene un cuerpo finito con $t = 3^2 = 9$ elementos, a saber:

$$\beta_0 = \{0, X^2 + X + 2, \dots\}$$

$$\beta_1 = \{1, X^2 + X, \dots\}$$

$$\beta_2 = \{X, X^2 + 2X + 2, \dots\}$$

$$\beta_3 = \{X^2, 2X + 1, \dots\}$$

$$\beta_4 = \{X^3, 2X + 2, \dots\}$$

$$\beta_5 = \{2, X^4, \dots\}$$

$$\beta_6 = \{2X, X^5, \dots\}$$

$$\beta_7 = \{X^6, X + 2, \dots\}$$

$$\beta_8 = \{X^7, X + 1, \dots\}.$$

Al sumar, restar, multiplicar y dividir (excepto por β_0) dos elementos cualesquiera, se obtiene siempre un elemento del cuerpo. Por ejemplo,

$$\beta_3 + \beta_6 = \{1\} + \{2\}X = \{4\}X + \{1\} = \{1\}X + \{1\} = \beta_8$$

$$\beta_3 * \beta_5 = X^2 * X^4 = X^6 = \beta_7$$

$$\frac{\beta_5}{\beta_2} = \frac{X^4}{X} = X^3 = \beta_4$$

$$\frac{\beta_2}{\beta_6} = \frac{X}{X^4} = \frac{X}{2} = 2X = \beta_6.$$

8.8.2. Geometrías finitas

En este caso, se considera inicialmente una geometría Euclidiana de dos dimensiones, teniendo como elementos los puntos (α_i, α_j) y las rectas $\alpha_i X + \alpha_j Y + \alpha_k = 0$, donde $(\alpha_i, \alpha_j) \neq (0, 0)$ en cada recta. Si $s = t^n$, con t un número primo y adoptando los axiomas convenientes, se demuestra que:

a) Número total de puntos es s^2 .

b) Número total de rectas es $s^2 + s$.

Las rectas se distribuyen en $s + 1$ grupos con s rectas paralelas, a saber:

a) $X = \alpha_i$, con $i = 0, 1, \dots, s - 1$ (punto X).

b) $Y = \alpha_j$, con $j = 0, 1, \dots, s - 1$ (punto Y).

c) $Y = \alpha_k X + \alpha_j$, con $k = 1, \dots, s - 1$ y $j = 0, 1, \dots, s - 1$ (puntos U_k).

Para obtener una geometría proyectiva finita, se introducen $s + 1$ nuevos puntos (llamados puntos impropios o del infinito) y una nueva recta (recta impropia o del infinito). Los $s + 1$ nuevos puntos son X, Y, U_k ($k = 1, \dots, s - 1$) cada uno correspondiente a uno de los $s + 1$ grupos de rectas paralelas dadas anteriormente. Ahora, se tendrán $s^2 + s + 1$ puntos. Considerando una nueva recta que pasa por los $s + 1$ puntos impropios, se tiene $s^2 + s + 1$ rectas, se nota que:

a) Cada recta contiene $s + 1$ puntos (s propios y un impropio).

b) Por cada punto pasan $s + 1$ rectas.

c) Dos rectas cualesquiera se cortan siempre en un punto.

8.8.3. Cuadros latinos ortogonales

Considere los puntos impropios X y Y , definidos como se vio en la sección anterior, por los grupos de rectas:

$$X = \alpha_i, \quad \text{con } i = 0, 1, \dots, s-1. \quad (\text{punto } X)$$

$$Y = \alpha_j, \quad \text{con } j = 0, 1, \dots, s-1. \quad (\text{punto } Y)$$

Las s rectas del primer grupo cortan las s rectas del segundo grupo en s^2 puntos propios distintos, que se pueden designar por (α_i, α_j) con $i, j = 0, 1, \dots, s-1$. Considere un grupo de rectas que pasan por el punto U_k donde $k = 1, 2, \dots, s-1$. Por el punto U_k pasan s rectas propias r_u correspondientes a los elementos α_u ($u = 0, 1, 2, \dots, s-1$). Si la recta correspondiente a α_u , pasa por los puntos (α_i, α_j) en la posición (i, j) de la matriz se escribe α_u , obteniéndose, así, con las s rectas que pasan por U_k , un cuadro latino. Tomando $k = 1, 2, \dots, s-1$, se obtiene $s-1$ cuadros latinos que son ortogonales.

Ejemplo 8.13. Suponga un número primo $t = 5$ y considere un cuerpo de Galois formado por los siguientes elementos:

$$\alpha_0 = \{0, 5, 10, \dots, -5, -10, \dots\}$$

$$\alpha_1 = \{1, 6, 11, \dots, -4, -9, \dots\}$$

$$\alpha_2 = \{2, 7, 12, \dots, -3, -8, \dots\}$$

$$\alpha_3 = \{3, 8, 13, \dots, -2, -7, \dots\}$$

$$\alpha_4 = \{4, 9, 14, \dots, -1, -6, \dots\}$$

Se pueden indicar estos elementos así:

$$\alpha_0 = (0) \quad \alpha_1 = (1) \quad \alpha_2 = (2) \quad \alpha_3 = (3) \quad \alpha_4 = (4)$$

Para construir dos cuadros latinos ortogonales de tamaño 5×5 , se toman inicialmente las rectas

$$X = \alpha_i, \quad \text{con } i = 0, 1, 2, 3, 4.$$

$$Y = \alpha_j, \quad \text{con } j = 0, 1, 2, 3, 4.$$

y, además, la recta

$$Y = \alpha_j + \alpha_k + \alpha_i \quad \text{con } k = 0, 1, 2, 3, 4.$$

Para $\alpha_k = \alpha_1 = (1)$, se tiene la ecuación del primer cuadro latino cuyos elementos son $m_{ij} = (\alpha_i, \alpha_j) = (\alpha_j + \alpha_i \alpha_k)$. Por ejemplo, para el primer cuadro latino, con $\alpha_k = \alpha_1 = (1)$, se obtiene: $Y = \alpha_j + \alpha_i$.

La ecuación de la tercera línea está dada por $\alpha_i = 2$ porque $Y = \alpha_j + (2)$.

		α_j				
		0	1	2	3	4
α_i	0	0	1	2	3	4
	1	1	2	3	4	0
	2	2	3	4	0	1
	3	3	4	0	1	2
	4	4	0	1	2	3

El elemento 0 de la cuarta columna tercera fila será:

$$Y = \alpha_3 + (2) = (3) + (2) = (5) = (0).$$

Los elementos de la tercera línea serán entonces

$$\alpha_0 + (2), \alpha_1 + (2), \alpha_2 + (2), \alpha_3 + (2), \alpha_4 + (2),$$

esto es,

$$(2), (3), (4), (0), (1).$$

El segundo cuadro latino, ortogonal al primero, tendrá la ecuación:

$$Y = \alpha_j + 2\alpha_j.$$

La quinta línea corresponderá a $\alpha_i = (4)$ y tendrá la ecuación:

$$Y = \alpha_j + 2(4) = \alpha_j + 2(3).$$

Y sus elementos serán los puntos

$$(3), (4), (0), (1), (2)$$

		α_j				
		0	1	2	3	4
α_i	0	0	1	2	3	4
	1	2	3	4	0	1
	2	4	0	1	2	3
	3	1	2	3	4	0
	4	3	4	0	1	2

Un tercer cuadro latino ortogonal a los anteriores, está dado por la ecuación:

$$Y = \alpha_j + (3)\alpha_i.$$



Capítulo *nueve* Experimentos factoriales

9.1. Características generales

El término experimento o arreglo factorial hace referencia a la constitución de los tratamientos o combinaciones de niveles de tratamientos que se desea comparar. El término experimento factorial no afecta lo que se conoce como *diseño de tratamientos*, pues este se refiere a la selección de factores que se desea estudiar, los niveles de los factores a ensayar y la combinación de estos.

Es relevante aclarar que el diseño de tratamientos es independiente del diseño experimental, el cual hace referencia a la manera en que los tratamientos se aleatorizan con las diferentes unidades experimentales y a la forma en que se controla la variabilidad natural de las mismas como se evidencia en el capítulo uno. Así, el diseño experimental puede ser completamente aleatorizado, bloques completamente aleatorizados, cuadros latinos, etc., y para cada uno de estos diseños se puede tener un arreglo factorial específico.

En muchos experimentos, el éxito o fracaso del ensayo depende más de la selección de los tratamientos a comparar que de la elección del diseño mismo. Sin embargo, la selección de ambos es importante, luego ninguno de los dos debe descuidarse en la planeación de un experimento controlado.

En un experimento factorial se investigan simultáneamente los efectos de cierto número de diferentes factores. La necesidad de estudiar conjuntamente varios factores obedece principalmente a dos razones:

- a. Encontrar un modelo que describa el comportamiento general del fenómeno en estudio. Esto se restringe al rango de variación de los niveles de los factores.
- b. Optimizar la respuesta o variable independiente, es decir, encontrar la combinación de niveles de los factores que optimizan esa respuesta.

Los tratamientos en el análisis factorial están constituidos por todas las combinaciones que se forman de los distintos niveles de los factores. Por ello, la característica esencial que hace necesario el estudio conjunto de factores es la posibilidad de que el efecto de un factor cambie en presencia de los niveles de otro factor (presencia de interacción), es decir, que los factores interactúen, lo cual conduce al concepto de *interacción* entre ellos.

Si se estudia un factor en forma separada, el resultado puede ser diferente al que resultaría de un estudio conjunto, y es más difícil describir el comportamiento general o encontrar la combinación óptima de niveles cuando se hace de forma separada.

Ejemplo 9.1. Méndez (1993) cita el siguiente ejemplo propuesto inicialmente por Finney (1955), quien presenta un experimento de factores por separado que

consiste en determinar las condiciones óptimas de almacenaje de los pescados en barcos pesqueros. Los factores estudiados fueron: temperatura, duración y método de empaque (proporción de hielo y pescado). La respuesta de interés es una medida de la calidad del pescado al descargue.

Al investigar únicamente la temperatura, se deben tener varios niveles de temperatura y mantener constante la duración y el empaque a niveles arbitrarios. Una vez obtenida una temperatura óptima (manteniendo los niveles constantes de duración y empaque), se investiga otro factor. Por ejemplo, el empaque con la temperatura óptima y un nivel arbitrario de duración. Si el empaque óptimo encontrado no es el que se seleccionó en la primera etapa, se deberá estudiar de nuevo la temperatura haciendo necesario ajustes sucesivos. Esto se conoce como experimentación secuencial.

Si el tiempo de obtención de la variable respuesta es corto y el costo económico es poco, se puede seguir este procedimiento en forma secuencial. En caso contrario, es más conveniente el uso de experimentos factoriales.

Los experimentos agrícolas en general no tienen esta característica, de ahí que estas técnicas se desarrollaron en el sector agropecuario con los trabajos pioneros de Fisher y Yates entre 1920 y 1930 en la estación agrícola experimental de Rothamsted en Inglaterra.

Observación 9.1. Los experimentos factoriales deben ser usados cuando los factores no son independientes, puesto que en general se busca evaluar el efecto de interacción.

Algunas de las ventajas de esta clase de experimentos son:

- i. Al obtener información sobre varios factores sin aumentar el tamaño del experimento hay economía en el material experimental.
- ii. Se amplía la base de la inferencia en relación con un factor, ya que se estudia en las diferentes condiciones representadas por los niveles de otros factores.
- iii. Se puede obtener una estimación de la interacción de los efectos, es decir, se determina el grado y la forma en la cual se modifica el efecto de un factor en presencia de los niveles de los otros factores.
- iv. El conjunto de los tratamientos en el diseño factorial es óptimo para estudiar efectos principales e interacciones.
- v. Se puede trabajar con un subconjunto de tratamientos (fracciones del diseño).

Entre las desventajas más importantes se destacan:

1. El gran número de combinaciones de tratamientos cuando se estudian muchos factores o muchos niveles. En forma simultánea esto tiene dos efectos:
 - a) Si se desea usar bloques completos, es difícil encontrar grupos de unidades experimentales homogéneos para asignar todos los tratamientos dentro del bloque. Esto se puede eliminar usando *el principio de confusión*.
 - b) Se aumenta el costo del experimento al tener muchas unidades experimentales. Este problema se minimiza usando experimentos factoriales fraccionados. En este caso, se lleva a cabo el análisis estadístico considerando solo una parte de los tratamientos posibles.
2. Dificil interpretación principalmente de las interacciones de orden superior (interacciones de más de tres efectos).

Los factores se acostumbran a denotar con letras mayúsculas: $A, B, C, \dots$. Los niveles de un factor se identifican con subíndices $a_i, b_j, c_k, \dots$. Los tratamientos se denotan de varias formas:

- a. Con letras y números, ejemplo: $a_1b_2c_3, a_1b_0c_1, \dots$, teniendo entonces

$$\begin{aligned} a_1b_2c_3 &= T_1 \\ a_1b_0c_1 &= T_2 \\ &\vdots \end{aligned}$$

- b. Únicamente con los números y el orden se indica el factor. Así, los tratamientos anteriores también se denotan como: $123 = T_1, 101 = T_2$, etc.

Es conveniente comenzar la numeración de niveles en cero. En el caso de factores cuantitativos, el nivel cero es el más bajo (generalmente ausencia de tratamiento). Los efectos de un factorial que se estudian se relacionan con los efectos principales y de interacción y se denotan por las letras A, B, C, AB, ABC , etc.

La interacción entre los factores se presenta cuando los niveles de un factor no producen medias poblacionales que guarden las mismas relaciones al considerar cada uno de los niveles del segundo factor (hay grandes cambios en la magnitud de estos). Este resultado se ilustra gráficamente en la

figura 9.1. Si las gráficas obtenidas estuvieran conformadas por las líneas b_0 , b'_1 y b_0 , b'_1 y b'_2 , no se tendría efecto de interacción. En ese caso, el efecto de cambiar los niveles de A sería el mismo para todos los niveles de B . Si las líneas son las dadas por b_0 , b_1 y b_0 , b_1 y b_2 (líneas continuas), el efecto de cambio de niveles de A sobre la respuesta es diferente dependiendo de los niveles de B (hay interacción) y viceversa.




Figura 9.1: Interacción entre dos factores.

Para definir la interacción entre tres factores, se toma un patrón de interacción entre dos de ellos, y si este patrón cambia al considerar los niveles del tercer factor, se tiene interacción entre los tres factores.

Para estudiar el efecto de una interacción, se debe evaluar primero la hipótesis de no interacción, la cual se “prueba” con una razón de cuadrados medios; si la hipótesis no se rechaza, se considera que no hay interacción. Si se rechaza la hipótesis nula, entonces mediante pruebas de comparación múltiple se debe investigar el patrón de la interacción.

9.2. Diseño factoriales 2^k

Los diseños factoriales se usan ampliamente en experimentos que incluyen varios factores, buscando estudiar el efecto conjunto de los factores sobre la respuesta. Hay varios casos especiales del diseño factorial que son importantes debido a su uso generalizado en investigación. Se destacan los arreglos 2^k porque constituyen las bases de otros diseños de gran valor práctico.

El más importante de estos arreglos se presenta cuando se ensayan k factores, cada uno con dos niveles. En este caso, se habla de arreglos factoriales 2^k . Los niveles de estos factores pueden ser cuantitativos o cualitativos.

La selección de únicamente dos niveles puede conducir a inferencias erróneas. Así, cuando la respuesta se afecta en forma cuadrática, los niveles estudiados pueden indicar que no hay efecto del factor, lo cual conduciría a tomar decisiones erradas.

En el caso de $k = 2$, se tiene el factorial más sencillo 2^2 , el modelo estadístico para este arreglo sería

$$y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + e_{ijk} = \mu + \tau_s + e_{ijk},$$

donde $\tau_s = \alpha_i + \beta_j + (\alpha\beta)_{ij}$, $i, j = 0, 1$, $k = 1, 2, \dots, n_{ij}$, con el número de réplicas $n_{ij} \geq 0$. El anterior modelo está asociado con un diseño factorial *completamente aleatorizado*.

Si el diseño es en bloques completos, el modelo estadístico es

$$y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \gamma_k + e_{ijk},$$

donde $i, j = 0, 1$, $k = 1, 2, \dots, b$, con b el número de bloques.

9.2.1. Diseño factorial 2^2

El primer diseño del tipo 2^k es el que solo considera dos factores, por ejemplo, A y B , cada uno con dos niveles. A este diseño se le llama *diseño factorial 2^2* . Los niveles de los factores pueden denominarse arbitrariamente “bajo” y “alto”. En este caso, se tienen cuatro tratamientos que se denotan por cualquiera de los siguientes símbolos:

Tratamiento	Notación		
1	(1)	a_0b_0	00
2	a	a_1b_0	10
3	b	a_0b_1	01
4	ab	a_1b_1	11

Los efectos se definen con base en las tablas de tratamientos, como se presenta a continuación:

Factor	B	
	b_0 (Bajo)	b_1 (Alto)
A	a_0 (Bajo)	$T_{a_0b_0}$ $T_{a_0b_1}$
	a_1 (Alto)	$T_{a_1b_0}$ $T_{a_1b_1}$

Con base en estos totales, se obtiene

$$A_{i=0} = T_{a_0b_0} + T_{a_0b_1} = 00 + 01 = (1) + b$$

y

$$A_{i=1} = T_{a_1b_0} + T_{a_1b_1} = 10 + 11 = a + ab$$

donde $T_{a_ib_j}$ hace referencia al total de todas las unidades experimentales que reciben el tratamiento ij . 00, 01, 10 y 11, al igual que (1), b , a y ab , se usan en el mismo sentido, según la notación adoptada.

Con base en los anteriores resultados, se define el efecto del factor A como

$$A = [A_{i=1} - A_{i=0}] \text{ mód } 2 = [A_1 - A_0] \text{ mód } 2.$$

Con base unitaria y considerando que cada tratamiento se estudia en r unidades experimentales, se define el efecto del factor A por

$$\begin{aligned}\hat{A} &= \frac{1}{2r} [A_{i=1} - A_{i=0}] \text{ mód } 2 = \frac{1}{2r} [10 + 11 - 01 - 00] \text{ mód } 2 \\ &= \frac{1}{2r} [a + ab - (1) - b] = \frac{1}{2r} (a - 1)(b + 1) \\ &= \bar{y}_{A^+} - \bar{y}_{A^-},\end{aligned}$$

lo cual quiere decir que el efecto de A puede encontrarse como la diferencia en la respuesta promedio de las dos combinaciones de tratamientos en los niveles altos de A ($\bar{y}_{A^+}$) y las dos combinaciones de tratamientos en los niveles bajos de A ($\bar{y}_{A^-}$).

En forma semejante, se encuentra la estimación de los efectos de B y AB

$$\begin{aligned}\hat{B} &= \frac{1}{2r} [B_{j=1} - B_{j=0}] \text{ mód } 2 = \frac{1}{2r} [01 + 11 - 00 - 10] \text{ mód } 2 \\ &= \frac{1}{2r} [b + ab - (1) - a] = \frac{1}{2r} (a + 1)(b - 1) \\ &= \bar{y}_{B^+} - \bar{y}_{B^-}\end{aligned}$$

y para efecto de interacción

$$\begin{aligned}(AB)_{i+j=1} &= 01 + 10 \\ (AB)_{i+j=0} &= 00 + 11.\end{aligned}$$

De este modo, el efecto de la interacción AB se define como la diferencia promedio entre el efecto de A con el nivel alto de B y el efecto de A con el nivel bajo de B . Por lo tanto,

$$\begin{aligned}\widehat{AB} &= \frac{1}{2r} [(AB)_{i+j=0} - (AB)_{i+j=1}] \text{ mód } 2 = \frac{1}{2r} [00 + 11 - 01 - 10] \text{ mód } 2 \\ &= \frac{1}{2r} [(1) + ab - a - b] = \frac{1}{2r} (a - 1)(b - 1).\end{aligned}$$

Otra forma de estudiar los efectos es a través de la tabla de contrastes con base en los signos positivos y negativos, como se presenta a continuación:

Efecto	$T_{a_0b_0}$ 00	$T_{a_0b_1}$ 01	$T_{a_1b_0}$ 10	$T_{a_1b_1}$ 11
A	-	-	+	+
B	-	+	-	+
AB	+	-	-	+

De la tabla anterior, se observa que el factorial es un experimento donde de antemano se han planteado contrastes ortogonales, entonces

$$SC(\text{Contraste}) = \frac{\left(\sum_{i=1}^t \lambda_i y_{i..} \right)^2}{r \sum_{i=1}^t \lambda_i^2} = r \frac{\left(\sum_{i=1}^t \lambda_i \hat{\tau}_i \right)^2}{\sum_{i=1}^t \lambda_i^2}, \quad (9.1)$$

donde $\hat{\tau}_i = \bar{y}_{i..} - \bar{y}_{...}$. De esta forma, se obtiene que

$$\begin{aligned} SC(A) &= r \frac{1}{4} \left(\sum_{i=1}^t \lambda_i \hat{\tau}_i \right)^2 = \frac{1}{4r} (A_{i=1} - A_{i=0})^2_{\text{mód } 2} \\ &= \frac{1}{4r} (T_{a_1b_1} + T_{a_1b_0} - T_{a_0b_1} - T_{a_0b_0})^2 = \frac{1}{4r} [11 + 10 - 01 - 00]^2_{\text{mód } 2} \\ SC(B) &= \frac{1}{4r} [B_{j=1} - B_{j=0}]^2_{\text{mód } 2} = \frac{1}{4r} [11 + 01 - 10 - 00]^2_{\text{mód } 2} \\ SC(AB) &= \frac{1}{4r} (AB_{i+j=0} - AB_{i+j=1})^2_{\text{mód } 2} = \frac{1}{4r} [11 + 00 - 10 - 01]^2_{\text{mód } 2}. \end{aligned}$$

La suma de cuadrados total se encuentra como

$$SCT_{CM} = \sum_{i=1}^2 \sum_{j=1}^2 \sum_{k=1}^r y_{ijk}^2 - \frac{y_{...}^2}{4r},$$

con $4r - 1$ grados de libertad. La suma de cuadrados del error, con $4(r - 1)$ grados de libertad, suele calcularse por diferencia como

$$SCE = SCT_{CM} - SC(A) - SC(B) - SC(AB).$$

Ejemplo 9.2. Suponga que se realizó un experimento en un diseño en cuadro latino con una estructura factorial 2^2 , para estudiar el efecto de fertilizantes orgánicos e inorgánicos en el cultivo de papa. El modelo propuesto es el siguiente:

$$y_{ijk} = \mu + C_i + D_j + \tau_k + e_{ijk}, \quad i, j, k = 1, 2, 3, 4,$$

donde y_{ijk} hace referencia al peso de la producción en libras en la i -ésima fila, j -ésima columna y k -ésimo tratamiento; C_i representa el efecto de la i -ésima fila; D_j representa el efecto de la j -ésima columna y τ_k es el efecto del k -ésimo tratamiento en el ensayo.

Los tratamientos empleados en el arreglo experimental fueron:

(1) Superfosfato.

(n) Sulfato de Amonio.

(p) Harina de Hueso.

(np) Superfosfato + Harina de Hueso.

Teniendo en cuenta el arreglo factorial 2^2 en las diferentes filas y columnas, se obtiene la tabla 9.1.

Tabla 9.1: Diseño en cuadro latino para estudiar el efecto de fertilizantes orgánicos e inorgánicos en el cultivo de papa

Peso	1		2		3		4	
<i>I</i>	645	(np)	667	(p)	670	(n)	787	(1)
<i>II</i>	752	(1)	637	(n)	655	(p)	576	(np)
<i>III</i>	642	(p)	627	(np)	745	(1)	675	(n)
<i>IV</i>	621	(n)	762	(1)	596	(np)	660	(p)

Por los motivos planteados anteriormente y dada la estructura factorial del ensayo, se propone el modelo:

$$y_{ijkl} = \mu + C_i + D_j + N_k + P_l + NP_{kl} + e_{ijkl}.$$

La tabla 9.2 corresponde al análisis de varianza para el conjunto de datos anterior. A partir de esta, se encuentra que $F_0 = 37.5 > F_{(3,6,0.05)} = 4.75$, por lo que se rechaza la hipótesis de igualdad de tratamientos. De esta manera, se debe realizar una partición apropiada de los tratamientos para determinar a cuál de ellos se deben estas diferencias.

Tabla 9.2: Análisis de varianza para el peso de la producción

C de V	gl	SC	CM	F_0	F
Filas	3	3320.19	1109.58		
Columnas	3	271.69	90.56		
Tratamiento	3	49678.69	16559.56	37.50	4.75
Error	6	2649.88	441.65		
Total	15	55920.45			

En el gráfico de la figura 9.2, se observa que en apariencia no hay interacción entre sulfato de Amonio (n) y harina de hueso (p).




Figura 9.2: Interacción entre p y n según el peso promedio de la producción.

Sin embargo, como lo anterior no es suficiente para concluir sobre el experimento, entonces se debe evaluar el efecto de cada factor y su interacción, para lo cual se obtienen las siguientes estimaciones:

1. Calcular los totales de los tratamientos:

$$(1) = 787 + 752 + 745 + 762 = 3046$$

Similarmente, se obtienen:

$$n = 2603 \quad p = 2624 \quad np = 2444.$$

2. Realizar la estimación de los efectos:

$$\begin{aligned} \hat{N} &= \frac{1}{(2)(4)}(10 + 11 - 00 - 01)_{\text{mód } 2} = \frac{1}{8}(n + np - (1) - p) \\ &= -\frac{623}{8} = -77.9 \end{aligned}$$

$$\begin{aligned} \hat{P} &= \frac{1}{(2)(4)}(01 + 11 - 00 - 10)_{\text{mód } 2} = \frac{1}{8}(p + np - (1) - n) \\ &= -\frac{581}{8} = -72.6 \end{aligned}$$

$$\begin{aligned} \widehat{NP} &= \frac{1}{(2)(4)}(00 + 11 - 10 - 01)_{\text{mód } 2} = \frac{1}{8}((1) + np - n - p) \\ &= \frac{263}{8} = 32.9. \end{aligned}$$

3. *Obtener las sumas de cuadrados asociadas a cada uno de los efectos involucrados en el modelo*

$$SC(N) = \frac{(-623)^2}{16} = 24258.06$$

$$SC(P) = \frac{(-581)^2}{16} = 21097.56$$

$$SC(NP) = \frac{(263)^2}{16} = 4323.06.$$

4. *Concluir sobre la hipótesis nula de que cada uno de los efectos es igual a cero. Para tal fin, se realiza:*

$$F_{NP} = \frac{CM(NP)}{CME} = \frac{4323.06}{441.6458} = 9.8$$

$$F_N = \frac{CM(N)}{CME} = \frac{24258.06}{441.6458} = 54.9$$

$$F_P = \frac{CM(P)}{CME} = \frac{21097.56}{441.6458} = 47.7.$$

A partir de los resultados anteriores, se concluye, al comparar con una $F_{(1,6,0.05)} = 5.98$, que existe efecto de interacción, lo cual quiere decir que hay diferencias en el peso de la producción entre los tratamientos con superfosfato, (1) y (np), y los no superfosfatados, (n) y (p). También hay efecto de la diferencia sobre el promedio de (P), es decir, entre tratamientos que tienen harina de hueso, ((p) y (np)), y los que no la tienen, ((1) y (n)).

Así mismo, existen diferencias en el efecto promedio de (N), esto quiere decir que los tratamientos (1) y (p) difieren de los tratamientos (n) y (np).

5. *Construir intervalos de confianza para cada uno de los factores involucrados en el modelo. Para tal fin, se tiene en cuenta el siguiente resultado*

$$V(\text{Contraste}) = \frac{\sigma^2}{4r} \sum_{i=1}^4 \lambda_i^2 = \frac{\sigma^2}{r},$$

pero como σ no se conoce, entonces la varianza se estima como

$$\hat{V}(\text{Contraste}) = \frac{CME}{4} = 110.41.$$

De esta forma, un intervalo de confianza al 95% para NP es

$$\widehat{NP} \pm t_{(6,0.025)} \sqrt{\hat{V}(\widehat{NP})} = 32.9 \pm (2.44)(10.50) = (7.27, 58.53).$$

De manera análoga, se procede con P y N , encontrando que

$$\hat{P} \pm t_{(6,0.025)} \sqrt{\hat{V}(\hat{P})} = -72.6 \pm (2.44)(10.50) = (-98.22, -46.98)$$

y

$$\hat{N} \pm t_{(6,0.025)} \sqrt{\hat{V}(\hat{N})} = -77.9 \pm (2.44)(10.50) = (-103.52, -52.28).$$

Los anteriores intervalos confirman los resultados encontrados en el numeral anterior sustentado en las pruebas F .

9.2.2. Diseño factorial 2^3

Cuando se tienen tres factores, A , B y C , con dos niveles cada uno, entonces hay un total de 8 tratamientos en investigación. A este diseño se le llama *diseño factorial 2^3* . En este caso, la representación geométrica de las ocho combinaciones de tratamientos puede hacerse con un cubo como se muestra en la figura 9.3.




Figura 9.3: Arreglo geométrico para un diseño factorial 2^3 .

Al igual que en el diseño factorial 2^2 , existen tres notaciones diferentes para los ocho tratamientos. La primera es la notación $+$ y $-$, llamada con frecuencia *notación geométrica*; la segunda es el uso de las letras minúsculas para identificar las combinaciones de los tratamientos y la tercera notación utiliza 1 y 0 para denotar los niveles alto y bajo, respectivamente, de los factores, en lugar de $+$ y $-$. Estas diferentes notaciones se ilustran en la tabla 9.3.

Tabla 9.3: Notaciones para un diseño 2^3

Tratamiento	A	B	C	Efecto	A	B	C
1	-	-	-	(1)	0	0	0
2	+	-	-	a	1	0	0
3	-	+	-	b	0	1	0
4	+	+	-	ab	1	1	0
5	-	-	+	c	0	0	1
6	+	-	+	ac	1	0	1
7	-	+	+	bc	0	1	1
8	+	+	+	abc	1	1	1

Hay siete grados de libertad en el diseño 2^3 . Tres grados de libertad se asocian con los efectos principales (A , B y C), tres grados de libertad se asocian a las interacciones dobles (AB , AC y BC) y la interacción triple (ABC). Los efectos principales e interacciones se definen con base en la siguiente suma de totales de tratamientos, la suma de los subíndices es módulo 2.

$$A_{i=0} = 000 + 001 + 010 + 011$$

$$A_{i=1} = 100 + 101 + 110 + 111$$

$$B_{j=0} = 000 + 001 + 101 + 100$$

$$B_{j=1} = 010 + 011 + 110 + 111$$

$$AB_{i+j=0} = 000 + 110 + 001 + 111$$

$$AB_{i+j=1} = 010 + 100 + 011 + 101$$

$$C_{k=0} = 000 + 100 + 010 + 110$$

$$C_{k=1} = 001 + 101 + 011 + 111$$

$$AC_{i+k=0} = 000 + 010 + 101 + 111$$

$$AC_{i+k=1} = 100 + 110 + 001 + 011$$

$$BC_{j+k=0} = 000 + 100 + 011 + 111$$

$$BC_{j+k=1} = 010 + 110 + 001 + 101$$

$$ABC_{i+j+k=0} = 000 + 110 + 101 + 011$$

$$ABC_{i+j+k=1} = 100 + 010 + 001 + 111.$$

El efecto promedio del factor A se obtiene teniendo en cuenta el promedio siguiente:

$$\begin{aligned}\hat{A} &= \frac{1}{4r} [A_{i=1} - A_{i=0}] \text{ mód } 2 \\ &= \frac{1}{4r} [100 + 101 + 110 + 111 - 000 - 001 - 010 - 011] \text{ mód } 2\end{aligned}$$

$$\begin{aligned}
\hat{A} &= \frac{1}{4r} [a_1 b_0 c_0 + a_1 b_0 c_1 + a_1 b_1 c_0 + a_1 b_1 c_1 - a_0 b_0 c_0 - a_0 b_0 c_1 - a_0 b_1 c_0 \\
&\quad - a_0 b_1 c_1] \\
&= \frac{1}{4r} [a + ac + ab + abc - (1) - c - b - bc] \\
&= \frac{1}{4r} (a - 1)(b + 1)(c + 1).
\end{aligned}$$

El anterior resultado puede descomponerse como sigue

$\bar{y}_{a_1 b_0 c_0} - \bar{y}_{a_0 b_0 c_0}$: efecto del factor A a los niveles 0, 0 de b y c .

$\bar{y}_{a_1 b_0 c_1} - \bar{y}_{a_0 b_0 c_1}$: efecto del factor A a los niveles 0, 1 de b y c .

$\bar{y}_{a_1 b_1 c_0} - \bar{y}_{a_0 b_1 c_0}$: efecto del factor A a los niveles 1, 0 de b y c .

$\bar{y}_{a_1 b_1 c_1} - \bar{y}_{a_0 b_1 c_1}$: efecto del factor A a los niveles 1, 1 de b y c .

Al sumar todas las observaciones y dividir entre 4, se tiene el promedio de ese tratamiento, es decir, el promedio de estas cuatro diferencias es el efecto A , el cual está dado por

$$\begin{aligned}
\hat{A} &= \frac{1}{4} [\bar{y}_{a_1 b_0 c_0} - \bar{y}_{a_0 b_0 c_0} + \bar{y}_{a_1 b_0 c_1} - \bar{y}_{a_0 b_0 c_1} + \bar{y}_{a_1 b_1 c_0} - \bar{y}_{a_0 b_1 c_0} + \bar{y}_{a_1 b_1 c_1} - \bar{y}_{a_0 b_1 c_1}] \\
&= \bar{y}_{A^+} - \bar{y}_{A^-}.
\end{aligned}$$

De manera similar, la estimación del efecto de B se obtiene a partir de la diferencia de los promedios entre las cuatro combinaciones de tratamientos, es decir,

$$\begin{aligned}
\hat{B} &= \frac{1}{4r} [B_{j=1} - B_{j=0}]_{\text{mód } 2} = \bar{y}_{B^+} - \bar{y}_{B^-} \\
&= \frac{1}{4r} [010 + 011 + 110 + 111 - 000 - 001 - 100 - 101]_{\text{mód } 2} \\
&= \frac{1}{4r} (a + 1)(b - 1)(c + 1),
\end{aligned}$$

y la estimación para el efecto de C es

$$\begin{aligned}
\hat{C} &= \frac{1}{4r} [C_{k=1} - C_{k=0}]_{\text{mód } 2} = \bar{y}_{C^+} - \bar{y}_{C^-} \\
&= \frac{1}{4r} [001 + 101 + 011 + 111 - 000 - 100 - 010 - 110]_{\text{mód } 2} \\
&= \frac{1}{4r} (a + 1)(b + 1)(c - 1).
\end{aligned}$$

Los efectos de la interacción de dos factores pueden calcularse con cierta facilidad. La interacción AB es la mitad de la diferencia entre los efectos promedio de A con los dos niveles de B . Utilizando los siguientes resultados, se encuentra la estimación de esta interacción.

B	Efecto promedio de A
Alto (+)	$\frac{1}{2}[(\bar{y}_{a_1b_1c_0} - \bar{y}_{a_0b_1c_0}) + (\bar{y}_{a_1b_1c_1} - \bar{y}_{a_0b_1c_1})]$
Bajo (-)	$\frac{1}{2}[(\bar{y}_{a_1b_0c_0} - \bar{y}_{a_0b_0c_0}) + (\bar{y}_{a_1b_0c_1} - \bar{y}_{a_0b_0c_1})]$

La diferencia entre las anteriores expresiones mide la discrepancia del efecto de A al combinar los niveles de B . A esto se le llama *efecto de interacción* AB y se divide entre dos para tener la misma base que los efectos principales. De este modo, se sigue que

$$\begin{aligned}\widehat{AB} &= \frac{1}{4}[\bar{y}_{a_1b_1c_0} - \bar{y}_{a_0b_1c_0} + \bar{y}_{a_1b_1c_1} - \bar{y}_{a_0b_1c_1} - \bar{y}_{a_1b_0c_0} + \bar{y}_{a_0b_0c_0} \\ &\quad - \bar{y}_{a_1b_0c_1} + \bar{y}_{a_0b_0c_1}] = \frac{1}{4r}[(AB)_{i+j=0} - (AB)_{i+j=1}] \text{ mód } 2 \\ &= \frac{1}{4r}[ab + abc + (1) + c - b - bc - a - ac] = \frac{1}{4r}(a-1)(b-1)(c+1).\end{aligned}$$

Utilizando un razonamiento similar, las interacciones AC y BC son estimadas como

$$\begin{aligned}\widehat{AC} &= \frac{1}{4r}[(AC)_{i+k=0} - (AC)_{i+k=1}] \text{ mód } 2 \\ &= \frac{1}{4r}[(1) + b + ac + abc - a - c - ab - bc] = \frac{1}{4r}(a-1)(b+1)(c-1) \\ \widehat{BC} &= \frac{1}{4r}[(BC)_{j+k=0} - (BC)_{j+k=1}] \text{ mód } 2 \\ &= \frac{1}{4r}[(1) + a + bc + abc - b - c - ab - ac] = \frac{1}{4r}(a+1)(b-1)(c-1).\end{aligned}$$

La interacción triple ABC se define como la diferencia entre AB en los dos niveles de C , por consiguiente,

$$\begin{aligned}\widehat{ABC} &= \frac{1}{4r}[(ABC)_{i+j+k=1} - (ABC)_{i+j+k=0}] \text{ mód } 2 \\ &= \frac{1}{4r}[(abc - bc) + (a - (1)) - (ac - c) - (ab - b)] \\ &= \frac{1}{4r}[abc + a + c + b - bc - (1) - ac - ab] \\ &= \frac{1}{4r}(a-1)(b-1)(c-1).\end{aligned}$$

De esta forma, la interacción ABC puede considerarse como la diferencia de dos promedios. Una construcción puede verse en Hinkelman y Kempthorne (2005)

En términos de contraste, los efectos e interacciones se definen a partir de los coeficientes que se presentan en la tabla 9.4. Los signos de los efectos principales se determinan asociando un signo positivo con el nivel alto y un signo negativo con el nivel bajo. Una vez que se han establecido los signos de los efectos principales, los signos de las filas restantes (de interacciones) pueden obtenerse multiplicando las filas precedentes apropiadas, columna por columna. Con la descomposición que se muestra en la tabla 9.4, se encuentra el contraste de cualquier efecto.

Tabla 9.4: Coeficientes para calcular los efectos en un diseño 2^3

Efecto	Tratamientos							
	000	100	010	110	001	101	011	111
Total	+1	+1	+1	+1	+1	+1	+1	+1
A	-1	+1	-1	+1	-1	+1	-1	+1
B	-1	-1	+1	+1	-1	-1	+1	+1
AB	+1	-1	-1	+1	+1	-1	-1	+1
C	-1	-1	-1	-1	+1	+1	+1	+1
AC	+1	-1	+1	-1	-1	+1	-1	+1
BC	+1	+1	-1	-1	-1	-1	+1	+1
ABC	-1	+1	+1	-1	+1	-1	-1	+1

La suma de cuadrados de los efectos se calcula con facilidad, ya que cada efecto tiene un contraste correspondiente con un solo grado de libertad. En el diseño 2^3 con r réplicas, la suma de cuadrados de cualquier efecto es

$$SC(Contraste) = \frac{1}{8r} (Contraste)^2 \quad (9.2)$$

y la varianza de la estimación de cada efecto es

$$V(Efecto) = V\left(\frac{Contraste}{4r}\right) = \frac{\sigma^2}{2r}.$$

En caso de tener varias observaciones para cada combinación de tratamientos, se obtiene la tabla 9.5 de análisis de varianza con r réplicas por combinaciones de tratamientos.

Tabla 9.5: Análisis de varianza para un diseño 2^3

Causa de variación	gl	SC	E(CM)
A	1	$2r[A]^2$	$\sigma^2 + 2r[A]^2$
B	1	$2r[B]^2$	$\sigma^2 + 2r[B]^2$
AB	1	$2r[AB]^2$	$\sigma^2 + 2r[AB]^2$
C	1	$2r[C]^2$	$\sigma^2 + 2r[C]^2$
AC	1	$2r[AC]^2$	$\sigma^2 + 2r[AC]^2$
BC	1	$2r[BC]^2$	$\sigma^2 + 2r[BC]^2$
ABC	1	$2r[ABC]^2$	$\sigma^2 + 2r[ABC]^2$
Error	$2^3(r - 1)$	$\sum_{ijkl} (y_{ijkl} - \bar{y}_{ijk.})^2$	σ^2
Total	$2^3r - 1$	$\sum_{ijkl} (y_{ijkl} - \bar{y}_{....})^2$	

Ejemplo 9.3. En Méndez (1993) se cita el siguiente ejemplo tomado de Federer (1955), en el cual se presenta un experimento para evaluar la efectividad de ayudas estereográficas en la educación de ingenieros. Los factores estudiados fueron: la clase equivalente a primer y cuarto año de carrera, con niveles freshman (F) y senior (S), dos tipos de preguntas y de gráficas, con niveles I (P_I el conjunto de preguntas I) y II (P_{II} el conjunto de preguntas II) y la exposición a derecha (E_D) o izquierda (E_I) de una fotografía de la figura estereográfica. El arreglo de los tratamientos se presenta en la tabla 9.6. En cada tratamiento se tenían 6 estudiantes. La respuesta de interés fue el porcentaje de respuestas correctas.

Tabla 9.6: Arreglo de los tratamientos para evaluar la efectividad de ayudas estereográficas en la educación de ingenieros

Tratamientos	Exposición	Preguntas	Clase
000:	E_I	P_I	F
100:	E_D	P_I	F
010:	E_I	P_{II}	F
110:	E_D	P_{II}	F
001:	E_I	P_I	S
101:	E_D	P_I	S
011:	E_I	P_{II}	S
111:	E_D	P_{II}	S

El primer conjunto de preguntas P_I contestadas tenía 27 preguntas y el segundo conjunto P_{II} tenía 18 preguntas. Esto podría ocasionar heterogeneidad de varianza. Para evitar esto, se obtuvo la contribución a la suma de cuadrados del error de cada tratamiento.

Los datos obtenidos en este experimento se presentan en la tabla 9.7.

Tabla 9.7: Número de respuestas correctas (C) e incorrectas (I)

Tratamiento															
000		100		010		110		001		101		011		111	
C	I	C	I	C	I	C	I	C	I	C	I	C	I	C	I
10	17	10	17	2	16	10	8	6	21	4	23	6	12	9	9
10	17	6	21	1	17	0	18	5	22	8	19	11	7	5	13
6	21	10	17	5	13	4	14	7	20	9	18	5	13	11	7
12	15	5	22	10	8	4	14	12	15	11	16	7	11	8	10
8	19	2	25	8	10	6	12	11	16	6	21	2	16	8	10
5	22	7	20	3	15	6	12	8	19	5	22	6	12	9	9

Se observa que las respuestas correctas (C) siguen una distribución binomial, entonces se hace necesario efectuar una transformación y buscar así una aproximación a la distribución normal (esto con efecto de ejemplificar, puesto que se podía hacer uso directamente del modelo binomial) dentro del contexto de los modelos lineales generalizados.

La transformación $Y = \arcsin \sqrt{X}$, donde X es el porcentaje de respuestas correctas, se presenta en la tabla 9.8 de datos transformados. Esta tabla se obtiene con dicha transformación y teniendo en cuenta que cuando se tiene el 0 % de respuestas correctas, se toma $\frac{100}{(4)(18)} = 1.39\%$.

Tabla 9.8: Datos transformados

Tratamiento								
000	100	010	110	001	101	011	111	
37.5	37.5	19.5	48.2	28.1	22.6	35.3	45.0	
37.5	28.1	13.6	6.8	25.5	33.0	51.4	31.8	
28.1	37.5	31.8	28.1	30.6	35.3	31.8	51.4	
41.8	25.5	48.2	28.1	41.8	39.7	38.5	41.8	
33.0	15.8	41.8	35.3	39.7	28.1	19.5	41.8	
25.5	30.6	24.1	35.3	33.0	25.5	35.3	45.0	

El modelo propuesto para los datos transformados es

$$y_{ijkl} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \gamma_k + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \epsilon_{ijkl},$$

con $i, j, k = 0, 1, l = 1, \dots, 6$ y $y_{ijk} = \arcsin \sqrt{x_{ijk}}$, α_i es el efecto de la i -ésima exposición, β_j es el j -ésimo conjunto de preguntas, γ_k es el efecto de la k -ésima clase, $(\alpha\beta)_{ij}$, $(\alpha\gamma)_{ik}$, $(\beta\gamma)_{jk}$ y $(\alpha\beta\gamma)_{ijk}$ son las interacciones dobles y triples entre los factores involucrados.

Con los datos transformados se realiza el análisis de varianza usual del DCA con ocho tratamientos ($t = 8$) y seis réplicas ($r = 6$) cada uno. El efecto de tratamientos se descompone en siete contrastes ortogonales que representan los efectos principales y las interacciones, como se presenta en la tabla 9.9.

Tabla 9.9: Signos para efectos principales e interacciones en un 2^3

Efecto	Totales de tratamiento								$\Sigma +$	$\Sigma -$
	000	100	010	110	001	101	011	111		
Total	203.4	175.0	179.0	181.8	198.7	184.2	211.8	256.8	1509.7	
<i>A</i>	+	+	+	+	+	+	+	+	797.9	792.9
<i>B</i>	-	-	+	+	-	-	+	+	829.4	761.3
<i>AB</i>	+	-	-	+	+	-	-	+	840.7	750.0
<i>C</i>	-	-	-	-	+	+	+	+	851.5	739.2
<i>AC</i>	+	-	+	-	-	+	-	+	823.4	767.3
<i>BC</i>	+	+	-	-	-	-	+	+	847.0	743.7
<i>ABC</i>	-	+	+	-	+	-	-	+	809.5	781.2

Al utilizar los totales teniendo en cuenta las combinaciones de los tratamientos que se muestran en la tabla 9.9, los efectos de los factores se estiman de la siguiente manera:

$$\begin{aligned}\hat{A} &= \frac{1}{4(6)}(175 + 181.8 + 184.2 + 256.8 - 203.4 - 179 - 198.7 \\ &\quad - 211.8) = \frac{1}{24}(797.9 - 792.9) = 0.20 \\ \hat{B} &= \frac{1}{24}(829.4 - 761.3) = 2.84 \\ \widehat{AB} &= \frac{1}{24}(840.7 - 750.0) = 3.78 \\ \hat{C} &= \frac{1}{24}(851.5 - 739.2) = 4.68 \\ \widehat{AC} &= \frac{1}{24}(823.4 - 767.3) = 2.34 \\ \widehat{BC} &= \frac{1}{24}(847.0 - 743.7) = 4.30 \\ \widehat{ABC} &= \frac{1}{24}(809.5 - 781.2) = 1.18.\end{aligned}$$

Los efectos que más contribuyen son para la clase ($\hat{C} = 4.68$), la interacción exposición-conjunto de preguntas ($\widehat{AB} = 3.78$) y la interacción conjunto de preguntas-clase ($\widehat{BC} = 4.30$). Adicionalmente, si bien el efecto de la interacción triple *ABC* no parece tener un impacto tan grande sobre la efectividad de ayudas estereográficas en la educación de ingenieros como otros efectos, el efecto de la misma debe verificarse a través de una prueba estadística.

Las sumas de cuadrados se obtienen a partir de la ecuación (9.2). En este caso, por ejemplo, la suma de cuadrados asociadas al factor *A* y la interacción *AB* son, respectivamente,

$$SC(A) = \frac{1}{8(6)} [797.9 - 792.9]^2 = \frac{(4.9)^2}{48} = 0.5$$

$$SC(AB) = \frac{1}{48} [750 - 840.7]^2 = \frac{(90.7)^2}{48} = 171.38.$$

Las demás sumas de cuadrados se obtienen en forma semejante, así, se llega al análisis de varianza que se resume en la tabla 9.10.

Tabla 9.10: Resultados del análisis de varianza para el porcentaje de respuestas correctas

Causa de variación	gl	SC	CM	F
Tratamientos	7	835.80	119.40	1.36
<i>A</i>	1	0.50	0.50	0.01
<i>B</i>	1	96.62	96.62	1.10
<i>AB</i>	1	171.38	171.38	1.96
<i>C</i>	1	262.73	262.73	3.00
<i>AC</i>	1	65.57	65.57	0.75
<i>BC</i>	1	222.31	222.31	2.54
<i>ABC</i>	1	16.68	16.68	0.19
Entre alumnos	40	3500.55	87.51	
Total	47	4336.35		

Como $F = 1.36 < F_{(7,40,0.05)} = 2.25$, entonces se concluye que no hay efecto de los factores estudiados en el aprendizaje del alumno.

Posiblemente, al usar bloques o covariables se puede reducir el error experimental, pues

$$CV = \frac{\sqrt{CME}}{\bar{y}_{...}} = \frac{\sqrt{87.51}}{33.14} = 28.2\%,$$

permitiendo así detectar diferencias entre los tratamientos.

9.2.3. Generalización del diseño factorial 2^k

Los métodos de análisis que se han presentado hasta el momento pueden generalizarse para el caso de un *diseño factorial* 2^k , es decir, un diseño con k factores que tienen dos niveles cada uno. El modelo estadístico incluye k efectos principales, $\binom{k}{2}$ interacciones de dos factores, $\binom{k}{3}$ interacciones de tres factores, hasta una interacción de k factores $\binom{k}{k}$. Esto significa que el modelo completo contendría $2^k - 1$ efectos.

El primer paso al trabajar con esta clase de experimentos es estimar los efectos de los factores principales y examinar sus signos y magnitudes. De esta manera, el experimentador obtiene información respecto a los factores y las interacciones que pueden ser importantes, así como también sobre en qué

direcciones deberán ajustarse estos factores para mejorar la respuesta asociada con el proceso de interés. Para formular el modelo inicial del experimento, por lo general, se elige el *modelo completo* (modelo saturado), en el cual se involucran todos los efectos principales y las interacciones, siempre que se haya hecho, al menos, una réplica.

En general, el contraste del efecto, por ejemplo $AB \cdots$, se determina expandiendo el miembro derecho de

$$\text{Contraste}_{AB\cdots} = (a \pm 1)(b \pm 1) \cdots,$$

donde el signo de cada grupo en el paréntesis es negativo si el factor está incluido en el efecto (contraste) y es positivo si el factor no está incluido.

Una vez que se han obtenido los contrastes de los efectos, se procede a realizar estimaciones de los efectos involucrados en el *modelo completo* y las sumas de cuadrados asociadas, de acuerdo con la expresión

$$Efecto = \frac{1}{2^{k-1}r}(\text{Contraste}) = \frac{1}{2^{k-1}r}(a \pm 1)(b \pm 1) \cdots \quad (9.3)$$

y

$$SC(Efecto) = \frac{1}{2^k r} [(a \pm 1)(b \pm 1) \cdots]^2 = r 2^{k-2} (Efecto)^2, \quad (9.4)$$

respectivamente.

El valor esperado de la anterior suma de cuadrados es

$$E[SC(Efecto)] = \sigma^2 + r 2^{k-2} [Efecto]^2.$$

Con base en estos resultados, se puede determinar cuáles efectos del conjunto de factores son estadísticamente significativos, así como sus intervalos de confianza. En seguida, se presenta la forma general para calcular el *error estándar de los efectos* y la forma de construcción de los intervalos de confianza para cualquier efecto o interacción.

Si $y_{i1}, y_{i2}, \dots, y_{ir}$ son las observaciones del i -ésimo tratamiento, entonces

$$S_i^2 = \frac{1}{r-1} \sum_{j=1}^r (y_{ij} - \bar{y}_{i.})^2, \quad i = 1, 2, \dots, 2^k$$

es una estimación de la varianza del i -ésimo tratamiento. Las estimaciones de la varianza en el arreglo 2^k pueden combinarse para dar una estimación de la varianza global, partiendo de la estimación

$$S^2 = CME = \frac{1}{2^k(r-1)} \sum_{i=1}^{2^k} \sum_{j=1}^r (y_{ij} - \bar{y}_{i.})^2$$

se obtiene la varianza de la estimación de cada efecto

$$V(Efecto) = V\left(\frac{Contraste}{2^{k-1}r}\right) = \frac{1}{(2^{k-1}r)^2}V(Contraste).$$

Cada contraste es una combinación lineal de los 2^k totales de tratamientos y cada total tiene r observaciones. Por consiguiente, $V(Contraste) = r2^k\sigma^2$. De este resultado, se sigue que

$$V(Efecto) = \frac{1}{2^{k-2}r}\sigma^2.$$

El error estándar estimado se obtiene sacando la raíz cuadrada de esta última expresión y sustituyendo σ^2 por su estimación (CME), es decir,

$$se(Efecto) = \sqrt{\frac{CME}{2^{k-2}r}}.$$

Para contrastar la hipótesis $H_0 : AB \cdots = 0$ ($H_0: efecto = 0$), se hace uso del estadístico de prueba

$$F = \frac{SC(Efecto)}{CME}.$$

Si este valor es mayor que $F_{(1, 2^k(r-1), \alpha)}$, se tiene evidencia para rechazar la hipótesis nula y se puede concluir que este efecto es importante para el estudio.

De la misma forma, los intervalos de confianza de $100(1 - \alpha) \%$ para los efectos (por ejemplo, $AB \cdots$) se calculan a partir de

$$Efecto \pm t_{(2^k(r-1), 1-\alpha/2)} \sqrt{\frac{CME}{2^{k-2}r}}.$$

En la tabla 9.11 se presenta la forma general del análisis de varianza para el diseño factorial 2^k con r réplicas, en la cual se resumen los resultados presentados anteriormente.

9.3. Experimentos Factoriales 3^k

Un *diseño factorial* 3^k es un arreglo de k factores que tienen tres niveles cada uno. Para efectos de comprensión, se hace referencia a los tres niveles de los factores como bajo, medio y alto. Existen varias notaciones para representar estos niveles de los factores. Una posibilidad es representar los niveles de los factores con los dígitos 0 (bajo), 1 (medio) y 2 (alto).

Tabla 9.11: Análisis de varianza para el arreglo factorial 2^k

C de V		gl	SC
Tratamientos		$2^k - 1$	$SCTrata$
k efectos	A	1	$SC(A)$
principales	B	1	$SC(B)$
	$\vdots$	$\vdots$	$\vdots$
	K	1	$SC(K)$
$\binom{k}{2}$ interacciones	AB	1	$SC(AB)$
de dos factores	AC	1	$SC(AC)$
	$\vdots$	$\vdots$	$\vdots$
	JK	1	$SC(JK)$
$\binom{k}{3}$ interacciones de	ABC	1	$SC(ABC)$
tres factores	ABD	1	$SC(ABD)$
	$\vdots$	$\vdots$	$\vdots$
	IJK	1	$SC(IJK)$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$\binom{k}{k} = 1$ interacción de	$AB \cdots K$	1	$SC(AB \cdots K)$
k factores			
Error		$2^k(r - 1)$	SCE
Total		$2^k r - 1$	SCT_{CM}

Cada combinación de tratamientos del diseño 3^k se denotará por k dígitos: el primer dígito indica el nivel del factor A , el segundo dígito indica el nivel del factor B , $\dots$, y el dígito k -ésimo indica el nivel del factor K .

Por ejemplo, en un diseño factorial 3^2 , se tiene:

		B		
		0	1	2
A	0	(0, 0)	(0, 1)	(0, 2)
	1	(1, 0)	(1, 1)	(1, 2)
	2	(2, 0)	(2, 1)	(2, 2)

donde (0, 0) denota la combinación de tratamientos correspondiente a A y B , ambos en el nivel bajo, y (0, 1) denota la combinación de tratamientos correspondiente a A en el nivel bajo y B en el nivel intermedio.

Cuando los niveles de un factor, por ejemplo A son tres el efecto de ese factor estará reflejado en la variabilidad de tres totales de tratamientos, A_0 , A_1 y A_2 , donde A_i representa el total obtenido al sumar todos los tratamientos con nivel i del factor A . También el efecto del factor A se puede estudiar como dos contrastes ortogonales entre esos tres totales. Así, al efecto principal de un factor con tres niveles se le asocian dos grados de libertad.

De acuerdo con el modelo lineal, se tienen dos comparaciones independientes para A , dados por las filas:

$$X_1 = 0, \quad X_1 = 1, \quad X_1 = 2$$

y el efecto de B tiene dos comparaciones independientes entre columnas:

$$X_2 = 0, \quad X_2 = 1, \quad X_2 = 2.$$

En el sistema de los diseños 3^k , cuando los factores son *cuantitativos* e igualmente espaciados, es común denotar los niveles bajo, intermedio y alto con -1 , 0 y $+1$, respectivamente. Este diseño es una de las alternativas experimentales que permite estudiar efectos de curvatura, además de efectos lineales y de interacción.

Cuando el experimentador se preocupa por la curvatura en función de la respuesta, es necesario tener en cuenta que:

1. El diseño 3^k no es la forma más eficiente de modelar una relación cuadrática. Los *diseños de superficie de respuesta* que se presentan en el capítulo 12 son más útiles y deben recomendarse en el estudio de la curvatura.
2. El diseño 2^k aumentado con los puntos centrales y puntos axiales (diseño central compuesto), como se presentará en el capítulo 12, es una buena alternativa para obtener una indicación de la curvatura. Permite conservar reducido el tamaño y la complejidad del diseño y, al mismo tiempo, obtener cierta protección contra la curvatura.

9.3.1. Diseño factorial 3^2

El diseño más simple del sistema 3^k es el diseño 3^2 , el cual tiene dos factores, cada uno con tres niveles, obteniendo un total de 9 tratamientos diferentes. Las combinaciones de tratamientos de este diseño se presenta en la figura 9.4.

Los nueve tratamientos se pueden escribir de varias maneras, algunas de las cuales se muestran en la tabla 9.12.

El modelo estadístico para el diseño 3^2 se puede escribir considerando el efecto individual de cada factor y de la interacción entre ambos, como se presenta a continuación:

$$y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + e_{ijk}, \quad (9.5)$$

con $i, j = 0, 1, 2$ y $k = 1, \dots, r$, donde α_i es el efecto del factor A , β_j representa el efecto del factor B y $(\alpha\beta)_{ij}$ representa el efecto de la interacción entre los dos factores.




Figura 9.4: Combinaciones de tratamientos en un diseño 3^2 .

Tabla 9.12: Diseño factorial 3^2 en dos notaciones.

Tratamiento		A	B	A	B
Bajo	Bajo	-1	-1	0	0
Medio	Bajo	0	-1	1	0
Alto	Bajo	1	-1	2	0
Bajo	Medio	-1	0	0	1
Medio	Medio	0	0	1	1
Alto	Medio	1	0	2	1
Bajo	Alto	-1	1	0	2
Medio	Alto	0	1	1	2
Alto	Alto	1	1	2	2

En consecuencia, se contrasta la hipótesis $H_0 : (\alpha\beta)_{ij} = 0$ (no hay efecto de interacción de los factores A y B sobre la variable respuesta). Al igual que en los diseños 2^k , si esta hipótesis no se rechaza, entonces se contrastan las hipótesis: $H_0 : \alpha_i = 0$ (no hay efecto significativo del factor A sobre la variable respuesta) y $H_0 : \beta_j = 0$ (no hay efecto significativo del factor B sobre la variable respuesta). Estas hipótesis se juzgarán con los resultados del ANOVA, para ello se obtienen las sumas de cuadrados de los tres efectos incluidos en el modelo (9.5), las cuales se calculan mediante los métodos usuales al utilizar diagramas de estructuras (porque se está suponiendo balanceamiento), los cuales fueron presentados en el capítulo 4. En este caso, las sumas de cuadrados están dadas por las siguientes expresiones:

$$SC(A) = \sum_{i=0}^2 \frac{y_{i..}^2}{3r} - \frac{y_{...}^2}{3^2 r}$$

$$SC(B) = \sum_{j=0}^2 \frac{y_{.j.}^2}{3r} - \frac{y_{...}^2}{3^2 r}$$

$$SC(AB) = \sum_{i=0}^2 \sum_{j=0}^2 \frac{y_{ij.}^2}{r} - \frac{y_{...}^2}{3^2 r} - SC(A) - SC(B).$$

La suma de cuadrados total se obtiene de la forma usual, es decir

$$SCT_{CM} = \sum_{i=0}^2 \sum_{j=0}^2 \sum_{k=0}^r y_{ijk}^2 - \frac{y_{...}^2}{3^2 r},$$

y la suma del error se calcula a partir de las diferencias

$$SCE = SCT_{CM} - SC(A) - SC(B) - SC(AB).$$

Los grados de libertad asociados con cada suma de cuadrados de esta última relación son, respectivamente,

$$3^2(r-1) = (3^2 r - 1) - (3 - 1) - (3 - 1) - (3 - 1)(3 - 1).$$

Con base en los resultados anteriores, en la tabla 9.13 se presenta el análisis de varianza para el diseño 3^2 . Se observa que este diseño requiere de al menos dos réplicas para tener grados de libertad en el error. Si F_0 es mayor al prefijado, se rechaza la correspondiente hipótesis nula y se concluye que la fuente de variación (según la hipótesis planteada) afecta de manera significativa la variable respuesta.

La partición de la interacción de dos factores AB puede hacerse de dos maneras. El primer método consiste en subdividir AB en dos *cuadrados latinos ortogonales*; el segundo método divide esta interacción en cuatro componentes, con un solo grado de libertad, que corresponden a $A_L B_L$, $A_L B_C$, $A_C B_L$ y $A_C B_C$. Este método tiene sentido siempre y cuando los factores involucrados sean cuantitativos.

Tabla 9.13: Análisis de varianza para el diseño factorial 3^2

C de V.	gl	SC	CM	F_0
A	2	$SC(A)$	$CM(A)$	$CM(A)/CME$
B	2	$SC(B)$	$CM(B)$	$CM(B)/CME$
AB	4	$SC(AB)$	$CM(AB)$	$CM(AB)/CME$
Error	$3^2(r-1)$	SCE	CME	
Total	$3^2 r - 1$	SCT_{CM}		

Los dos cuadrados latinos ortogonales que se obtienen mediante el primer método se muestran en la tabla 9.14, los cuales se obtienen al realizar la descomposición en las componentes $A^1 B^1$ y $A^1 B^2$ de la interacción ($AB = A^1 B^1 + A^1 B^2$).

Tabla 9.14: Totales de las combinaciones de los tratamientos con dos cuadrados latinos ortogonales

A					B				

Cuando se considera la expresión $A^p B^q$, se establece la convención de que el único exponente permitido en la primera letra es 1. Si el exponente de la primera letra no es 1, la expresión completa se eleva al cuadrado y los exponentes se reducen al módulo 3. Así, el efecto $A^2 B^1$ es lo mismo que $A^1 B^2$ porque $A^2 B^1 = (A^2 B^1)^2 = (A^4 B^2)_{\text{mód } 3} = (A^1 B^2)_{\text{mód } 3}$.

Nótese además que la variación entre $(A^1 B^2)_0$, $(A^1 B^2)_1$ y $(A^1 B^2)_2$ es la misma que entre $(A^2 B^1)_0$, $(A^2 B^1)_1$ y $(A^2 B^1)_2$, ya que en el primer caso los tres totales se forman por $i + 2j = 0, 1, 2$ (mód 3), al multiplicar por dos; considerando, módulo 3, se tiene que $i + 2j = 0$ es $2i + 4j = 0$, pero como $4(\text{mód } 3) = 1$ se reduce a $2i + j = 0$, $i + 2j = 1$ da $2i + j = 2$ a su vez $i + 2j = 2$ da $2i + j = 4 = 1_{\text{mód } 3}$, con esto, entonces, las equivalencias son las siguientes:

$$(A^1 B^2)_0 = (A^2 B^1)_0, \quad (A^1 B^2)_1 = (A^2 B^1)_2 \quad \text{y} \quad (A^1 B^2)_2 = (A^2 B^1)_1.$$

O, en términos de la notación de contrastes,

$$\begin{aligned} (A^1 B^2)_0 &= x_1 + 2x_2 = 0 \text{ mód } 3 \\ 2(x_1 + 2x_2) &= 2x_1 + 4x_2 = 2x_1 + x_2 = 0 \text{ mód } 3 \\ &= (A^2 B^1)_0. \end{aligned}$$

Por estas equivalencias, se busca en la estructura del diseño que la primera letra de la interacción de interés tenga coeficiente 1.

Los componentes $A^1 B^1$ y $A^1 B^2$ de la interacción AB no tienen significado real y, por lo general, no se incluyen en la tabla de análisis de varianza. Sin embargo, esta partición, en gran medida arbitraria, es muy útil para construir diseños más complejos. Además, no hay relación entre los componentes $A^1 B^1$ y $A^1 B^2$, y las componentes $A_L B_L$, $A_L B_C$, $A_C B_L$ y $A_C B_C$ de la interacción.

Ejemplo 9.4. En Kuehl (2001) se presenta la información de un ensayo en el cual un entomólogo realizó un experimento sobre la energía consumida por las abejas al beber. Para determinar el efecto de la temperatura del ambiente y la viscosidad del líquido en el consumo de energía. Los niveles de temperatura (T) fueron 20, 30 y 40 °C, la viscosidad del líquido se controló por las concentraciones de sacarosa (S), que eran de 20, 40 y 60 % del total de sólidos disueltos en el líquido que bebían las abejas. El entomólogo registró la energía gastada por las abejas en joules/segundo. Los datos que se presentan en la tabla 9.15 corresponden a tres réplicas de cada uno de los nueve tratamientos en DCA.

Tabla 9.15: Efecto de la temperatura del ambiente y viscosidad del líquido en la energía gastada por las abejas

Temperatura (°C)	Sacarosa (%)		
	20	40	60
20	3.1	5.5	7.9
	3.7	6.7	9.2
	4.7	7.3	9.3
30	6.0	11.5	17.5
	6.9	12.9	15.8
	7.5	13.4	14.7
40	7.7	15.7	19.1
	8.3	14.3	18.0
	9.5	15.9	19.9

El modelo propuesto para este conjunto de datos es:

$$y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \epsilon_{ijk},$$

con $i, j = 0, 1, 2$ y $k = 1, 2, 3$, donde y_{ijk} es la energía gastada en la i -ésima temperatura j -ésima concentración de sacarosa y k -ésima réplica, α_i es el efecto de la i -ésima temperatura, β_j es el efecto de la j -ésima concentración de sacarosa y $(\alpha\beta)_{ij}$ es el efecto de interacción entre la i -ésima temperatura y j -ésima concentración de sacarosa.

Las sumas de cuadrados de los efectos están dadas por:

$$\begin{aligned} SC(T) &= \sum_{i=0}^2 \frac{y_{i..}^2}{3r} - \frac{y_{...}^2}{3^2r} \\ &= \frac{57.4^2 + 106.2^2 + 128.4^2}{(3)(3)} - \frac{292^2}{(9)(3)} = 293.16 \end{aligned}$$

$$\begin{aligned} SC(S) &= \sum_{j=0}^2 \frac{y_{.j.}^2}{3r} - \frac{y_{...}^2}{3^2r} \\ &= \frac{57.4^2 + 103.2^2 + 131.4^2}{(3)(3)} - \frac{292^2}{(9)(3)} = 309.96 \end{aligned}$$

$$\begin{aligned} SC(TS) &= \sum_{i=0}^2 \sum_{j=0}^2 \frac{y_{ij.}^2}{r} - \frac{y_{...}^2}{3^2r} - SC(A) - SC(B) \\ &= \frac{11.5^2 + 19.5^2 + \dots + 57^2}{3} - \frac{292^2}{27} - 293.16 - 309.96 = 27.13. \end{aligned}$$

La suma de cuadrados total es:

$$SCT_{CM} = \sum_{i=0}^2 \sum_{j=0}^2 \sum_{k=0}^r y_{ijk}^2 - \frac{y_{...}^2}{3^2 r}$$

$$= (3.1^2 + 5.5^2 + \dots + 15.9^2 + 19.9^2) - \frac{292^2}{27} = 646.53,$$

y finalmente, la suma de cuadrados del error es:

$$SCE = SCT_{CM} - SC(T) - SC(S) - SC(TS)$$

$$= 646.53 - 293.16 - 309.96 - 27.13 = 16.28.$$

Los grados de libertad de $SC(T)$, $SC(S)$ y $SC(TS)$ son 2, 2 y 4, respectivamente. En total el experimento tiene $3^2 - 1 = 26$ grados de libertad, quedando entonces $26 - 2 - 2 - 4 = 18$ grados de libertad para el residuo.

Al particionar la suma de cuadrados de la interacción TS , los dos cuadrados latinos ortogonales generados se muestran en la tabla 9.16, los cuales se obtienen al realizar la descomposición en las componentes T^1S^1 y T^1S^2 de la interacción. Cada una de estas componentes tiene dos grados de libertad.

Tabla 9.16: Totales de las combinaciones de los tratamientos

S				S			
T	20	40	60	T	20	40	60
20	11.5 (Q)	19.5 (R)	26.4 (S)	20	11.5 (Q)	19.5 (R)	26.4 (S)
30	20.4 (R)	37.8 (S)	48.0 (Q)	30	20.4 (S)	37.8 (Q)	48.0 (R)
40	25.5 (S)	45.9 (Q)	57.0 (R)	40	25.5 (R)	45.9 (S)	57.0 (Q)

Cuadrado T^1S^1

Cuadrado T^1S^2

Las sumas de cuadrados asociadas con T^1S^1 y T^1S^2 son, respectivamente,

$$SC(T^1S^1) = \frac{[(TS)_{i+j=0}]^2 + [(TS)_{i+j=1}]^2 + [(TS)_{i+j=2}]^2}{3r} - \frac{y_{...}^2}{9r}$$

$$= \frac{105.4^2 + 96.9^2 + 89.7^2}{(3)(3)} - \frac{292^2}{(9)(3)} = 13.73$$

y

$$SC(T^1S^2) = \frac{[(TS)_{i+2j=0}]^2 + [(TS)_{i+2j=1}]^2 + [(TS)_{i+2j=2}]^2}{3r} - \frac{y_{...}^2}{9r}$$

$$= \frac{106.3^2 + 92.7^2 + 93^2}{(3)(3)} - \frac{292^2}{(9)(3)} = 13.40.$$

Entonces, se observa que

$$SC(TS) = SC(T^1S^1) + SC(T^1S^2) = 13.73 + 13.40 = 27.13.$$

Con base en la información anterior, se obtiene la tabla 9.17 del análisis de varianza. De la tabla se concluye que hay efecto de la interacción entre temperatura y la sacarosa, ya que $F = 7.49 > F_{(4,18,0.05)} = 2.93$. En dicha tabla, aunque se haga la partición de la interacción TS y esta sea ortogonal, se señala de nuevo que no se acostumbra presentarla en la tabla de análisis de varianza. En el capítulo siguiente, se analiza la necesidad ocasional de calcular uno de estos componentes.

Tabla 9.17: Análisis de varianza para la energía gastada por las abejas

C. de V.	gl	SC	CM	F
Tratamiento	8	630.25	78.78	87.05
Temperatura (T)	2	293.16	146.58	162.00
Sacarosa (S)	2	309.96	154.98	171.25
$T*S$	4	27.13	6.78	7.49
T^1S^1	2	13.73	6.86	7.58
T^1S^2	2	13.40	6.70	7.40
Error	18	16.28	0.905	
Total	26	646.53		

En la figura 9.5, se ilustra la interacción entre temperatura y sacarosa, en ella se observa que la interacción no es tan marcada y también que los dos factores a través de la energía gastada por las abejas no se comporta necesariamente en forma lineal. Esto hace que se deba estudiar un posible efecto cuadrático de estos factores sobre la respuesta como se muestra más adelante.

Cuando los factores son cuantitativos, se subdivide la interacción AB en cuatro componentes, con un grado de libertad cada uno, cada partición corresponde a los efectos de curvas de tendencia de respuesta A_LB_L , A_LB_C , A_CB_L y A_CB_C .

En la figura 9.6, se representan los efectos de un factor a tres niveles. En dicha figura, la diferencia entre tratamientos con $\mu_{a_1} - \mu_{a_0}$ es el incremento debido al aumento de nivel de 0 a 1. Similarmente, $\mu_{a_2} - \mu_{a_1}$ es el incremento al cambiar de niveles de 1 a 2. Las μ_{a_i} son estimadas por $\bar{y}_{a_i}$.

El efecto lineal es el promedio de incrementos de $\bar{y}_{a_0}$ a $\bar{y}_{a_1}$ y de $\bar{y}_{a_1}$ a $\bar{y}_{a_2}$, así,

$$A_L = \frac{1}{2}[(a_1 - a_0) + (a_2 - a_1)] = \frac{1}{2}[a_2 - a_0].$$

El efecto cuadrático (o desviaciones de la linealidad) es la diferencia de incrementos entre los niveles alto y bajo. Si la linealidad es perfecta, esa diferencia será cero, y si hay discrepancias, se debe a la curvatura (como solo son tres puntos se considera una curvatura de tipo cuadrático).

$$A_C = \frac{1}{2}[(a_2 - a_1) - (a_1 - a_0)] = \frac{1}{2}[a_2 - 2a_1 + a_0].$$




Figura 9.5: Interacción entre temperatura y sacarosa con base en la energía promedio gastada por las abejas.




Figura 9.6: Efectos para un factor a tres niveles.

Cuando se tienen dos factores, como es el de caso del factorial 3^2 , los efectos principales se evalúan cambiando los denominadores pero aquí se

presenta la interacción entre esos dos factores. Si ambos factores son cuantitativos, puede resultar interesante el estudio de la interacción en términos de los efectos cuadráticos y lineales, esto es, investigando cómo cambia el efecto lineal de un factor al modificar los niveles del otro; análogamente, para el efecto cuadrático. Esto es fácil efectuarlo usando contrastes ortogonales. Una manera de asignar esos dos contrastes en el caso de factores cuantitativos es la que asigna el efecto lineal y cuadrático de ese factor a los contrastes.

Los coeficientes para los contrastes de la interacción se obtienen mediante el producto de los signos de contrastes de los coeficientes correspondientes a efectos principales, como se ilustra en la tabla 9.18.

Tabla 9.18: Coeficientes para contrastes en un factorial 3^2 , con ambos factores cuantitativos

Efecto global	Efecto individual	Tratamientos								
		a_0b_0 00	a_0b_1 01	a_0b_2 02	a_1b_0 10	a_1b_1 11	a_1b_2 12	a_2b_0 20	a_2b_1 21	a_2b_2 22
A	A_L	-1	-1	-1	0	0	0	1	1	1
	A_C	1	1	1	-2	-2	-2	1	1	1
B	B_L	-1	0	1	-1	0	1	-1	0	1
	B_C	1	-2	1	1	-2	1	1	-2	1
AB	A_LB_L	1	0	-1	0	0	0	-1	0	1
	A_LB_C	-1	2	-1	0	0	0	1	-2	1
	A_CB_L	-1	0	1	2	0	-2	-1	0	1
	A_CB_C	1	-2	1	-2	4	-2	1	-2	1

La interpretación de los términos de interacción se debe hacer sobre la forma de cambio de un efecto principal al cambiar los niveles del otro. Así, por ejemplo, si A_LB_L es significativo, indica que el efecto lineal de A cambia linealmente al cambiar los niveles de B . Un esquema de este patrón se presenta en la figura 9.7.

De modo semejante, si un efecto A_LB_C es significativo, indica que el efecto lineal de A cambia en forma cuadrática al modificar los niveles de B . Esto se esquematiza en la figura 9.8. En esta misma interacción se puede interpretar también cómo cambia el efecto cuadrático de B al modificar los niveles de A . En las figuras 9.7 y 9.8 solo se indica una de las muchas posibilidades de las situaciones descritas.

Si la hipótesis $H_0 : \mu_{a_2} - \mu_{a_0} = 0$ se rechaza, se concluye que hay efecto lineal. Si la hipótesis $H_0 : (\mu_{a_2} - \mu_{a_1}) - (\mu_{a_1} - \mu_{a_0}) = 0$, es decir, $H_0 : \mu_{a_2} - 2\mu_{a_1} + \mu_{a_0} = 0$ se rechaza, se concluye que el incremento de la μ_{a_1} a μ_{a_2} es diferente al incremento en las medias de μ_{a_0} a μ_{a_1} , esto quiere decir que hay efecto cuadrático del factor A . De modo similar, al rechazar la hipótesis de nulidad de un contraste, se concluye que el efecto considerado es significativo.




Figura 9.7: Respuesta con interacción $A_L B_L$.




Figura 9.8: Respuesta con interacción $A_L B_C$.

Las expresiones usuales para la suma de cuadrados de los contrastes se obtienen a partir de la expresión (9.1). En particular, al hacer uso de la tabla 9.18, la suma de cuadrados asociada al efecto A_L es

$$SC(A_L) = \frac{[(20) + (21) + (22) - (00) - (01) - (02)]^2_{\text{mód } 3}}{r(6)}.$$

En la expresión anterior, los símbolos (20), $\dots$, (02) denotan los totales de los tratamientos con esos niveles de los factores en el orden indicado. De forma semejante, se obtienen todas las SC de los ocho contrastes, dos de ellas son:

$$SC(B_C) = \frac{[(00) - 2(01) + (02) + (10) - 2(11) + (12) + (20) - 2(21) + (22)]^2_{\text{mód } 3}}{r(18)}$$

$$SC(A_C B_L) = \frac{[-(00) + (02) + 2(10) - 2(12) - (20) + (22)]^2_{\text{mód } 3}}{r(12)}.$$

En este caso, se consideran efectos fijos ya que se seleccionan los niveles de los factores para que sean igualmente espaciados.

Ejemplo 9.5. Considerando los datos del ejemplo 9.4 y suponiendo que se desea investigar el efecto de curvatura de la temperatura del ambiente y viscosidad del líquido sobre la energía gastada por las abejas.

En la tabla 9.19, se presentan las diferentes sumas de cuadrados. Algunas de las sumas presentadas en dicha tabla se obtienen como

$$SC(T_L) = \frac{[(20) + (21) + (22) - (00) - (01) - (02)]^2_{\text{mód } 3}}{(3)(6)}$$

$$= \frac{(25.5 + 45.9 + 57.0 - 11.5 - 19.5 - 26.4)^2}{18} = \frac{(71)^2}{18} = 280.05$$

$$SC(S_C) = \frac{[(00) - 2(01) + (02) + (10) - 2(11) + (12) + (20) - 2(21) + (22)]^2_{\text{mód } 3}}{(3)(18)}$$

$$= \frac{[11.5 - 2(19.5) + 26.4 + 20.4 - 2(37.8) + 48.0 + 25.5 - 2(45.9) + 57.0]^2}{54} = \frac{(-17.6)^2}{54} = 5.73$$

$$SC(T_C S_L) = \frac{[-(00) + (02) + 2(10) - 2(12) - (20) + (22)]^2_{\text{mód } 3}}{(3)(12)}$$

$$= \frac{[-11.5 + 26.4 + 2(20.4) - 2(48.0) - 25.5 + 57.0]^2}{36}$$

$$= \frac{(-8.8)^2}{36} = 2.15.$$

A partir de los resultados de la tabla 9.19, obsérvese que

$$SC(TS) = SC(T_L S_L) + SC(T_L S_C) + SC(T_C S_L) + SC(T_C S_C)$$

$$= 22.96 + 1.87 + 2.15 + 0.15 = 27.13.$$

De la tabla 9.20, se concluye que el efecto lineal de la temperatura del ambiente cambia linealmente al modificar los niveles del % de sacarosa. Esta conclusión se hace porque $F = 25.37 > F_{(1,18,0.05)} = 4.41$ y, además, se observa la similaridad entre las figuras 9.7 y 9.5. Los demás efectos en los que se descompone la interacción no son significativos.

Tabla 9.19: Sumas de cuadrados para la energía gastada por las abejas

Efecto	Tratamientos									Contr	SC
	00	01	02	10	11	12	20	21	22		
T_L	-1	-1	-1	0	0	0	1	1	1	71	280.05
T_C	1	1	1	-2	-2	-2	1	1	1	-26.6	13.10
S_L	-1	0	1	-1	0	1	-1	0	1	74	304.22
S_C	1	-2	1	1	-2	1	1	-2	1	-17.6	5.73
$T_L S_L$	1	0	-1	0	0	0	-1	0	1	16.6	22.96
$T_L S_C$	-1	2	-1	0	0	0	1	-2	1	-8.2	1.87
$T_C S_L$	-1	0	1	2	0	-2	-1	0	1	-8.8	2.15
$T_C S_C$	1	-2	1	-2	4	-2	1	-2	1	4	0.15

Tabla 9.20: Análisis de varianza para el efecto de curvatura en la energía gastada por las abejas

C. de V.	gl	SC	CM	F
Tratamiento	8	630.25	78.78	87.05
T	2	293.16	146.58	162.00
	T_L	1	280.05	280.05
	T_C	1	13.10	13.10
S	2	309.96	154.98	171.25
	S_L	1	304.22	304.22
	S_C	1	5.74	5.74
T*S	4	27.13	6.78	7.49
	$T_L S_L$	1	22.96	22.96
	$T_L S_C$	1	1.87	1.87
	$T_C S_L$	1	2.15	2.15
	$T_C S_C$	1	0.15	0.15
Error	18	16.28	0.91	
Total	26	646.53		

9.3.2. Diseño factorial 3^3

Suponga ahora que hay tres factores (A , B y C) bajo estudio y que cada factor tiene tres niveles dispuestos en un experimento factorial. Se trata de un diseño 3^3 , la disposición experimental y la notación de las combinaciones se presentan en la figura 9.9. En el ensayo se tienen 26 grados de libertad para los tratamientos. Cada efecto principal con 2 grados de libertad, la interacción de dos factores con 4 grados de libertad y la interacción de tres factores tiene 8 grados de libertad. Si se hacen r réplicas, hay $r3^3 - 1$ grados de libertad para el total y $3^3(r - 1)$ grados de libertad de error.




Figura 9.9: Combinaciones de tratamientos en un diseño factorial 3^3 .

El modelo estadístico para el diseño 3^3 en un DCA se puede escribir considerando el efecto individual de cada factor y, las interacciones dobles y triples, como se presenta a continuación:

$$y_{ijkl} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \gamma_k + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + e_{ijkl}, \quad (9.6)$$

con $i, j, k = 0, 1, 2$ y $l = 1, \dots, r$, donde y_{ijkl} hace referencia a la respuesta asociada a la l -ésima observación del tratamiento (ijk) , α_i , β_j y γ_k denotan los efectos de los factores A , B y C , respectivamente, $(\alpha\beta)_{ij}$, $(\alpha\gamma)_{ik}$ y $(\beta\gamma)_{jk}$ representan los efectos de interacción dobles, $(\alpha\beta\gamma)_{ijk}$ representa la interacción entre los tres factores y e_{ijkl} es el error experimental, el cual se supone se distribuye $N(0, \sigma^2)$.

Las sumas de cuadrados pueden calcularse utilizando los métodos estándares para los diseños factoriales. En este caso, para el factorial 3^3 , y en general para los 3^k , se cuenta con tres formas de obtener la suma de cuadrados debida, por ejemplo, a la interacción entre A y B .

Primera forma. De las reglas para cálculo de SC , gl y demás componentes del ANOVA, estudiadas en el capítulo 4, se encuentra que

$$SC(AB) = \frac{\sum_{i=0}^2 \sum_{j=0}^2 y_{ij..}^2}{3r} - \frac{\sum_{i=0}^2 y_{i...}^2}{9r} - \frac{\sum_{j=0}^2 y_{.j..}^2}{9r} - \frac{y_{....}^2}{27r}.$$

Segunda forma. En caso de que los factores A y B sean cuantitativos, como se vio anteriormente, hay cuatro contrastes ortogonales con los coeficientes dados en la tabla 9.18. Así, en factoriales 3^3 al utilizar dicha tabla y sumar

sobre el factor C se llega a

$$\begin{aligned}
 SC(A_L B_L) &= \frac{[y_{a_0 b_0} - y_{a_0 b_2} - y_{a_2 b_0} + y_{a_2 b_2}]^2}{(4)(3r)} \\
 SC(A_L B_C) &= \frac{[-y_{a_0 b_0} + 2y_{a_0 b_1} - y_{a_0 b_2} + y_{a_2 b_0} - 2y_{a_2 b_1} + y_{a_2 b_2}]^2}{(12)(3r)} \\
 SC(A_C B_L) &= \frac{[-y_{a_0 b_0} + y_{a_0 b_2} + 2y_{a_1 b_0} - 2y_{a_1 b_2} - y_{a_2 b_0} + y_{a_2 b_2}]^2}{(12)(3r)} \\
 SC(A_C B_C) &= \frac{1}{(36)(3r)} [y_{a_0 b_0} - 2y_{a_0 b_1} + y_{a_0 b_2} - 2y_{a_1 b_0} + 4y_{a_1 b_1} \\
 &\quad - 2y_{a_1 b_2} + y_{a_2 b_0} - 2y_{a_2 b_1} + y_{a_2 b_2}]^2.
 \end{aligned}$$

Por lo tanto,

$$SC(AB) = SC(A_L B_L) + SC(A_L B_C) + SC(A_C B_L) + SC(A_C B_C).$$

Tercera forma. También es posible hacer la partición de la suma de cuadrados de la interacción AB , como se presentó anteriormente, usando teoría de grupos (ver anexo 9.7).

$$SC(A^1 B^1) = \frac{[(AB)_{i+j=0}]^2 + [(AB)_{i+j=1}]^2 + [(AB)_{i+j=2}]^2}{9r} - \frac{y_{....}^2}{27r}.$$

Esta es la variación entre los totales generados con $i + j$, esto es, de $(A^1 B^1)_0$, $(A^1 B^1)_1$ y $(A^1 B^1)_2$, con 2 grados de libertad en cada grupo.

La variación entre los totales generados con $i + 2j = 0, 1, 2 \pmod{3}$ es:

$$SC(A^1 B^2) = \frac{[(AB)_{i+2j=0}]^2 + [(AB)_{i+2j=1}]^2 + [(AB)_{i+2j=2}]^2}{9r} - \frac{y_{....}^2}{27r}.$$

Entonces, al igual que cuando los factores son cuantitativos,

$$SC(AB) = SC(A^1 B^1) + SC(A^1 B^2).$$

Si los factores son cualitativos, se usan las formas 1 ó 3 para llevar a cabo la prueba de la hipótesis de nulidad de efecto de interacción. Si la hipótesis se rechaza, se hace una gráfica como las mencionadas anteriormente (ver figura 9.8) y, usando comparaciones múltiples, se investiga en donde está la posible causa de interacción. Para las demás interacciones dobles se realiza un procedimiento similar.

Para la interacción entre los tres factores del 3^3 también se tienen tres formas alternativas para el estudio o descomposición de la suma de cuadrados. Una de ellas es usando las reglas para SC (modelo completo), incorporando

al modelo del diseño experimental, el modelo de tratamientos; la segunda es mediante ocho contrastes ortogonales del tipo $A_L B_L C_L$, $A_C B_L C_C$, etc.; y la tercera es la que usa teoría de grupos y se describe a continuación.

Los ocho grados de libertad de la interacción se descomponen en la variación dentro de cuatro subconjuntos de tres totales cada uno. Estos subconjuntos de totales se definen como sigue:

1. Con $i + j + k = 0, 1, 2 \pmod{3}$ se genera un grupo de tres totales, cuya suma de cuadrados es $SC(A^1 B^1 C^1)$, y tiene dos grados de libertad.
2. Con $i + j + 2k = 0, 1, 2 \pmod{3}$ se genera un grupo de tres totales, cuya suma de cuadrados es $SC(A^1 B^1 C^2)$, y tiene dos grados de libertad.
3. Con $i + 2j + k = 0, 1, 2 \pmod{3}$ se genera un grupo de tres totales, cuya suma de cuadrados es $SC(A^1 B^2 C^1)$, y tiene dos grados de libertad.
4. Con $i + 2j + 2k = 0, 1, 2 \pmod{3}$ se genera un grupo de tres totales, cuya suma de cuadrados es $SC(A^1 B^2 C^2)$, y tiene dos grados de libertad.

Un ejemplo de cómo se obtienen estas sumas de cuadrados es

$$SC(A^1 B^1 C^2) = \frac{[(ABC)_{i+j+2k=0}]^2 + [(ABC)_{i+j+2k=1}]^2 + [(ABC)_{i+j+2k=2}]^2}{9r} - \frac{y_{\dots}^2}{27r}.$$

Así, si el factorial 3^3 está en un diseño en bloques aleatorizados, un esquema de su análisis de varianza se presenta en la tabla 9.21.

Un ejemplo muy completo de un factorial 3^k con varias formas de análisis se presenta a continuación, citado por (Méndez 1993).

Ejemplo 9.6. *En una planta industrial se estudió el efecto de los factores días, operadores y concentraciones de solventes en el rendimiento de la planta. Días y operadores eran efectos cualitativos y las concentraciones fueron 0.5, 1.0 y 2.0, que aunque no son igualmente espaciadas, sus logaritmos sí son igualmente espaciados y se usan si se desea observar la forma de la respuesta a través de este factor.*

El diseño experimental fue completamente aleatorizado y los factores se consideraron fijos. Se hicieron tres repeticiones de cada uno de los 27 tratamientos. Los datos codificados, a los que se les restó 20 para simplificar los cálculos, se presenta en la tabla 9.22.

Si se ajusta el modelo (9.6), el análisis de varianza se obtiene usando las reglas para SC, gl y CM presentas anteriormente. Por ser efectos fijos se prueban las hipótesis de cada efecto dividiendo los CM de efectos entre el CME.

Tabla 9.21: Análisis de varianza para un diseño factorial 3^3 en bloques

C de V	gl	Relación de definición
Bloques	$r - 1$	
Tratamientos	26	
A	2	$x_1 = 0, 1, 2 \text{ mód } 3$
B	2	$x_2 = 0, 1, 2 \text{ mód } 3$
AB	4	
A^1B^1	2	$x_1 + x_2 = 0, 1, 2 \text{ mód } 3$
A^1B^2	2	$x_1 + 2x_2 = 0, 1, 2 \text{ mód } 3$
C	2	$x_3 = 0, 1, 2 \text{ mód } 3$
AC	4	
A^1C^1	2	$x_1 + x_3 = 0, 1, 2 \text{ mód } 3$
A^1C^2	2	$x_1 + 2x_3 = 0, 1, 2 \text{ mód } 3$
BC	4	
B^1C^1	2	$x_2 + x_3 = 0, 1, 2 \text{ mód } 3$
B^1C^2	2	$x_2 + 2x_3 = 0, 1, 2 \text{ mód } 3$
ABC	8	
$A^1B^1C^1$	2	$x_1 + x_2 + x_3 = 0, 1, 2 \text{ mód } 3$
$A^1B^1C^2$	2	$x_1 + x_2 + 2x_3 = 0, 1, 2 \text{ mód } 3$
$A^1B^2C^1$	2	$x_1 + 2x_2 + x_3 = 0, 1, 2 \text{ mód } 3$
$A^1B^2C^2$	2	$x_1 + 2x_2 + 2x_3 = 0, 1, 2 \text{ mód } 3$
Error	$26(r - 1)$	
Total	$27r - 1$	

En este caso, al hacer uso del modelo (9.6), con $r = 3$, y_{ijkl} hace referencia al rendimiento de la planta asociado con la l -ésima observación del tratamiento (ijk) , α_i es el efecto del día i , β_j es el efecto del operador j , γ_k es el efecto de concentración k , $(\alpha\beta)_{ij}$ es el efecto de interacción de día i con operador j , $(\alpha\gamma)_{ik}$ es el efecto de interacción de día i con concentración k , $(\beta\gamma)_{jk}$ es el efecto de interacción de operador j con concentración k y $(\alpha\beta\gamma)_{ijk}$ es el efecto de interacción de los tres factores. El análisis de varianza para este conjunto de datos se presenta en la tabla 9.25.

Con estos datos, se ilustra la descomposición de la interacción DOC, aunque ello no debería hacerse, ya que no son significativas. Para esto se requieren las tablas de totales para esa interacción. En las tablas 9.23 y 9.24 se presentan con la finalidad de ilustrar los totales para $(D^1O^1C^1)$ y $(D^1O^2C^2)$, respectivamente.

Tabla 9.22: Efecto de los factores días, operadores y concentraciones en el rendimiento de la planta

Concentraciones			Días (D)							
			$5/14$			$5/15$			$5/16$	
			Operadores (O)							
C	A	B	C	A	B	C	A	B	C	
0.5	1.0	0.2	0.2	1.0	1.0	1.2	1.7	0.2	0.5	
	1.2	0.5	0.0	0.0	0.0	0.0	1.2	0.7	1.0	
	1.7	0.7	0.3	0.5	0.0	0.5	1.2	1.0	1.7	
1.0	5.0	3.2	3.5	4.0	3.2	3.7	4.5	3.7	3.7	
	4.7	3.7	3.5	3.5	3.0	4.0	5.0	4.0	4.5	
	4.2	3.5	3.2	3.5	4.0	4.2	4.7	4.2	3.7	
2.0	7.5	6.0	7.2	6.5	5.2	7.0	6.7	7.5	6.2	
	6.5	6.2	6.5	6.0	5.7	6.7	7.5	6.0	6.5	
	7.7	6.2	6.7	6.2	6.5	6.8	7.0	6.0	7.0	

Tabla 9.23: Totales del rendimiento de la planta por tratamiento para $(D^1O^1C^1)$

$(DOC)_{i+j+k=0}$		$(DOC)_{i+j+k=1}$		$(DOC)_{i+j+k=2}$	
Tratam	Suma	Tratam	Suma	Tratam	Suma
000	3.9	001	13.9	002	21.7
012	18.4	010	1.4	011	10.4
021	10.2	022	20.4	020	0.5
102	18.7	100	1.5	101	11.0
111	10.2	112	17.4	110	1.0
120	1.7	121	11.9	122	20.5
201	14.2	202	21.2	200	4.1
210	1.9	211	11.9	212	19.5
222	19.7	220	3.2	221	11.9
Total	98.9	Total	102.8	Total	100.6

Las cuatro sumas de cuadrados ortogonales en las que se puede particionar el efecto DOC son:

$$\begin{aligned}
 SC(D^1O^1C^1) &= \frac{[(DOC)_0]^2 + [(DOC)_1]^2 + [(DOC)_2]^2}{9(3)} - \frac{y_{\dots}^2}{27(3)} \\
 &= \frac{98.9^2 + 102.8^2 + 100.6^2}{27} - \frac{302.3^2}{81} = 0.28
 \end{aligned}$$

Tabla 9.24: Totales del rendimiento de la planta por tratamiento para $(D^1O^2C^2)$

$(DOC)_{i+2j+2k=0}$		$(DOC)_{i+2j+2k=1}$		$(DOC)_{i+2j+2k=2}$	
Tratam	Suma	Tratam	Suma	Tratam	Suma
000	3.9	002	21.7	001	13.9
012	18.4	011	10.4	010	1.4
021	10.2	020	0.5	022	20.4
101	11.0	100	1.5	102	18.7
110	1.0	112	17.4	111	10.2
122	20.5	121	11.9	120	1.7
202	21.2	201	14.2	200	4.1
211	11.9	210	1.9	212	19.5
220	3.2	222	19.7	221	11.9
Total	101.3	Total	99.2	Total	101.8

$$SC(D^1O^1C^2) = \frac{99.8^2 + 102.4^2 + 100.1^2}{27} - \frac{302.3^2}{81} = 0.15$$

$$SC(D^1O^2C^1) = \frac{103.2^2 + 100.0^2 + 99.1^2}{27} - \frac{302.3^2}{81} = 0.34$$

$$SC(D^1O^2C^2) = \frac{101.3^2 + 99.2^2 + 101.8^2}{27} - \frac{302.3^2}{81} = 0.14.$$

De estos resultados, se encuentra que

$$\begin{aligned} SC(DOC) &= SC(D^1O^1C^1) + SC(D^1O^1C^2) + SC(D^1O^2C^1) \\ &\quad + SC(D^1O^2C^2) = 0.28 + 0.15 + 0.34 + 0.14 = 0.91. \end{aligned}$$

Las demás sumas de cuadrados se presentan en la tabla 9.25, solamente con la finalidad de ilustrar también la descomposición de las interacciones dobles, pero recordando que estas no se suele presentar en el análisis de varianza y no tienen sentido.

A partir de los resultados obtenidos en la tabla 9.25, se encuentra que el efecto de concentración es muy grande (se puede observar a simple vista de los datos). Además, hay efecto de días, de operadores y de su interacción. Por ser tan grande el efecto de concentración y, además, por tratarse de un factor cuantitativo, es conveniente investigar el tipo de efecto que causa sobre la respuesta.

Los cálculos manuales para las sumas de cuadrados lineales y cuadráticas se muestran en la tabla 9.26.

Tabla 9.25: Análisis de varianza para la producción de la planta

C. de V.	gl	SC	CM	F
Día	2	3.48	1.74	9.49
Operador	2	6.10	3.05	16.65
DO	4	3.75	0.94	5.12
D^1O^1	2	2.25	1.12	6.25
D^1O^2	2	1.50	0.75	4.17
Concentración	2	465.35	232.68	1270.00
DC	4	0.49	0.12	0.66
D^1C^1	2	0.26	0.13	0.72
D^1C^2	2	0.23	0.11	0.64
OC	4	0.78	0.19	1.06
O^1C^1	2	0.59	0.29	1.64
O^1C^2	2	0.19	0.09	0.53
DOC	8	0.91	0.11	0.63
$D^1O^1C^1$	2	0.28	0.14	0.78
$D^1O^1C^2$	2	0.15	0.07	0.42
$D^1O^2C^1$	2	0.34	0.17	0.94
$D^1O^2C^2$	2	0.14	0.07	0.38
Error	54	9.89	0.18	
Total	80	490.76		

Tabla 9.26: Partición de las sumas de cuadrados de contraste lineal y cuadrático para la interacción triple

Día	Operador	Concentración			Lineal	Cuadrático
		0.5	1.0	2.0	$\sum_k \lambda_{L_k} y_{ijk.}$	$\sum_k \lambda_{C_k} y_{ijk.}$
5/14	A	3.9	13.9	21.7	17.8	-2.2
	B	1.4	10.4	18.4	17.0	-1.0
	C	0.5	10.2	20.4	19.9	0.5
5/15	A	1.5	11.0	18.7	17.2	-1.8
	B	1.0	10.2	17.4	16.4	-2.0
	C	1.7	11.9	20.5	18.8	-1.6
5/16	A	4.1	14.2	21.2	17.1	-3.1
	B	1.9	11.9	19.5	17.6	-2.4
	C	3.2	11.9	19.7	16.5	-0.9
	$y_{..k.}$	19.2	105.6	177.5		
	$\sum_k \lambda_{\Delta_k} y_{..k.}$				158.3	-14.5
Lineal	λ_{L_k}	-1	0	1		
cuadrático	λ_{C_k}	1	-2	1		

Las dos sumas de cuadrados en las que se puede particionar el efecto DOC, al descomponer el efecto de la concentración en lineal y cuadrático, son:

$$\begin{aligned}
 SC(DOC_L) &= \frac{\sum_{ij} \left(\sum_k \lambda_{L_k} y_{ijk.} \right)^2}{3 \sum_k \lambda_{L_k}^2} - \frac{\sum_i \left(\sum_k \lambda_{L_k} y_{i.k.} \right)^2}{3^2 \sum_k \lambda_{L_k}^2} - \frac{\sum_j \left(\sum_k \lambda_{L_k} y_{.jk.} \right)^2}{3^2 \sum_k \lambda_{L_k}^2} + \frac{\left(\sum_k \lambda_{L_k} y_{..k.} \right)^2}{3^3 \sum_k \lambda_{L_k}^2} \\
 &= \frac{(17.8^2 + \dots + 16.5^2)}{(3)(2)} - \frac{(54.7^2 + 52.4^2 + 51.2^2)}{(9)(2)} \\
 &\quad - \frac{(52.1^2 + 51.0^2 + 55.2^2)}{(9)(2)} + \frac{158.3^2}{(27)(2)} = 0.819
 \end{aligned}$$

y

$$\begin{aligned}
 SC(DOC_C) &= \frac{\sum_{ij} \left(\sum_k \lambda_{C_k} y_{ijk.} \right)^2}{3 \sum_k \lambda_{C_k}^2} - \frac{\sum_i \left(\sum_k \lambda_{C_k} y_{i.k.} \right)^2}{3^2 \sum_k \lambda_{C_k}^2} - \frac{\sum_j \left(\sum_k \lambda_{C_k} y_{.jk.} \right)^2}{3^2 \sum_k \lambda_{C_k}^2} + \frac{\left(\sum_k \lambda_{C_k} y_{..k.} \right)^2}{3^3 \sum_k \lambda_{C_k}^2} \\
 &= \frac{[(-2.2)^2 + \dots + (-0.9)^2]}{(3)(6)} - \frac{[(-2.7)^2 + (-5.4)^2 + (-6.4)^2]}{(9)(6)} \\
 &\quad - \frac{[(-7.1)^2 + (-5.4)^2 + (-2.0)^2]}{(9)(6)} + \frac{(-14.5)^2}{(27)(6)} = 0.098.
 \end{aligned}$$

Entonces, la suma de cuadrados DOC es

$$\begin{aligned}
 SC(DOC) &= SC(DOC_L) + SC(DOC_C) \\
 &= 0.819 + 0.098 = 0.917.
 \end{aligned}$$

Las demás sumas de cuadrados se presentan en la tabla 9.27, solamente con el propósito de ilustrar la descomposición también de las interacciones con el factor concentración, ya que algunas de las interacciones no son significativas porque el valor del estadístico de prueba es menor que el de la tabla. Además, el análisis de varianza presentado en la tabla 9.27, indica una interacción entre día y operador significativa ($F = 5.12 > F_{(4,18,0.05)} = 2.93$), y el factor concentración no interactúa con estos dos factores. Sin embargo, este afecta a la producción de la planta de forma cuadrática ($F = 7.08 > F_{(1,18,0.05)} = 4.41$), aunque esta forma funcional de la concentración no afecta la respuesta en la misma proporción que la forma lineal de este factor ($F = 2532.91$).

9.3.3. Generalización del diseño factorial 3^k

Los conceptos utilizados en los diseños 3^2 y 3^3 pueden extenderse, por ejemplo, al caso de k factores, cada uno con tres niveles, es decir, a un diseño 3^k . Se emplea la notación usual para las combinaciones de tratamientos, por ejemplo, 00120 representa una combinación de tratamientos en un diseño 3^5 con A, B y E en los niveles bajos, C en el nivel medio y D en el nivel alto. Hay 3^k combinaciones de tratamientos, con $3^k - 1$ grados de libertad entre ellas.

Tabla 9.27: Análisis de varianza para el efecto de curvatura en la producción de la planta

C. de V.	gl	SC	CM	F
Día	2	3.48	1.74	9.49
Operador	2	6.10	3.05	16.65
DO	4	3.75	0.94	5.12
Concentración	2	465.35	232.68	1270.00
C_L	1	464.05	464.05	2532.91
C_C	1	1.30	1.30	7.08
DC	4	0.49	0.12	0.66
DC_L	2	0.35	0.17	0.96
DC_C	2	0.14	0.07	0.37
OC	4	0.78	0.19	1.06
OC_L	2	0.53	0.26	1.44
OC_C	2	0.25	0.12	0.68
DOC	8	0.91	0.11	0.63
DOC_L	4	0.82	0.20	1.12
DOC_C	4	0.09	0.02	0.13
Error	54	9.89	0.18	
Total	80	490.76		

Las anteriores combinaciones de tratamientos permiten determinar las sumas de cuadrados de k efectos principales, cada uno con dos grados de libertad; $\binom{k}{2}$ interacciones de dos factores, cada una con cuatro grados de libertad, hasta obtener finalmente una interacción de k factores con 2^k grados de libertad. En general, una interacción de h factores tiene 2^h grados de libertad. Si se hacen r réplicas, hay $r3^k - 1$ grados de libertad para el total y $3^k(r - 1)$ para el error.

Las sumas de cuadrados de los efectos y las interacciones se calculan con los métodos usuales de cálculo para los diseños factoriales. De manera típica, no se hace ninguna descomposición adicional de las interacciones de tres factores y de órdenes superiores. Sin embargo, cualquier interacción de h factores tiene 2^{h-1} componentes ortogonales con dos grados de libertad. Por ejemplo, la interacción con cuatro factores $ABCD$ tiene $2^{4-1} = 8$ componentes ortogonales con dos grados de libertad, estas descomposiciones están denotadas por $A^1B^1C^1D^1$, $A^1B^1C^1D^2$, $A^1B^1C^2D^1$, $A^1B^2C^1D^1$, $A^1B^1C^2D^2$, $A^1B^2C^1D^2$, $A^1B^2C^2D^1$ y $A^1B^2C^2D^2$. Al escribirse estos componentes, se observa que el único exponente permitido en la primera letra es 1. Si el exponente de la primera letra no es 1, entonces la expresión completa debe elevarse al cuadrado y los exponentes deben reducirse al módulo 3, como se ilustró anteriormente. Se debe notar que la descomposición en estos

componentes no tienen interpretación, pero son útiles para construir diseños más complejos.

El tamaño del diseño se incrementa rápidamente con k factores. Por ejemplo, un diseño 3^3 tiene 27 combinaciones de tratamientos por réplica, un diseño 3^4 tiene 81, un diseño 3^5 tiene 243, etc. Esto hace que con frecuencia solo se considere una réplica del diseño 3^k , y las interacciones de orden superior (tres o más) se combinen para proporcionar una estimación del error.

9.4. Implementación en SAS

A partir de los datos de los ejemplos 9.2, 9.3, 9.4 y 9.6 desarrollados a lo largo del capítulo, se presentan a continuación los programas en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos.

```
/* Diseño factorial 2^2 */
/* Lectura de los datos del ejemplo 9.2 como un DCL */

DATA EJEMPL092;
INPUT FILA COLUMNA TRATA PESO @@;
CARDS;
1 1 4 645 1 2 3 667 1 3 2 670 1 4 1 787 2 1 1 752 2 2 2 637 2 3 3 655
2 4 4 576 3 1 3 642 3 2 4 627 3 3 1 745 3 4 2 675 4 1 2 621 4 2 1 762
4 3 4 596 4 4 3 660
;

PROC GLM DATA=EJEMPL092;
CLASS FILA COLUMNA TRATA;
MODEL PESO=FILA COLUMNA TRATA;
MEANS TRATA/LSD SCHEFFE;

/* Lectura de los datos del ejemplo 9.2 como un diseño factorial 2x2 */

DATA EJEMPL092;
INPUT FILA COLUMNA N P PESO @@;
CARDS;
1 1 1 1 645 1 2 0 1 667 1 3 1 0 670 1 4 0 0 787 2 1 0 0 752 2 2 1
0 637 2 3 0 1 655 2 4 1 1 576 3 1 0 1 642 3 2 1 1 627 3 3 0 0 745
3 4 1 0 675 4 1 1 0 621 4 2 0 0 762 4 3 1 1 596 4 4 0 1 660
;

PROC GLM DATA=EJEMPL092;
CLASS FILA COLUMNA N P;
MODEL PESO=FILA COLUMNA N|P;
```



```
/*Con la opción LSMEANS se obtiene las medias ajustadas por los
demás términos del modelo*/
```

```
LSMEANS N*P/TDIFF;
```

```
/* Diseño factorial 2^3 */
```

```
/* Lectura de los datos del ejemplo 9.3 */
```

```
DATA EJEMPLO93;
```

```
INPUT EXPOSIC $ PREGUNTA $ CLASE $ REPLICA TPORC @@;
```

```
CARDS;
```

```
EI PI F 1 37.5 EI PI F 2 37.5 EI PI F 3 28.1
EI PI F 4 41.8 EI PI F 5 33.0 EI PI F 6 25.5
ED PI F 1 37.5 ED PI F 2 28.1 ED PI F 3 37.5
ED PI F 4 25.5 ED PI F 5 15.8 ED PI F 6 30.6
EI PII F 1 19.5 EI PII F 2 13.6 EI PII F 3 31.8
EI PII F 4 48.2 EI PII F 5 41.8 EI PII F 6 24.1
ED PII F 1 48.2 ED PII F 2 6.8 ED PII F 3 28.1
ED PII F 4 28.1 ED PII F 5 35.3 ED PII F 6 35.3
EI PI S 1 28.1 EI PI S 2 25.5 EI PI S 3 30.6
EI PI S 4 41.8 EI PI S 5 39.7 EI PI S 6 33.0
ED PI S 1 22.6 ED PI S 2 33.0 ED PI S 3 35.3
ED PI S 4 39.7 ED PI S 5 28.1 ED PI S 6 25.5
EI PII S 1 35.3 EI PII S 2 51.4 EI PII S 3 31.8
EI PII S 4 38.5 EI PII S 5 19.5 EI PII S 6 35.3
ED PII S 1 45.0 ED PII S 2 31.8 ED PII S 3 51.4
ED PII S 4 41.8 ED PII S 5 41.8 ED PII S 6 45.0
;
```

```
PROC GLM DATA=EJEMPLO93;
```

```
CLASS EXPOSIC PREGUNTA CLASE;
```

```
MODEL TPORC=EXPOSIC|PREGUNTA|CLASE;
```

```
/* Diseño factorial 3^2 */
```

```
/* Lectura de los datos del ejemplo 9.4 */
```

```
DATA EJEMPLO94;
```

```
INPUT TEMPERATURA SACAROSA REPLICA ENERGIA @@;
```

```
CARDS;
```

```
20 20 1 3.1 20 40 1 5.5 20 60 1 7.9
20 20 2 3.7 20 40 2 6.7 20 60 2 9.2
20 20 3 4.7 20 40 3 7.3 20 60 3 9.3
30 20 1 6.0 30 40 1 11.5 30 60 1 17.5
30 20 2 6.9 30 40 2 12.9 30 60 2 15.8
30 20 3 7.5 30 40 3 13.4 30 60 3 14.7
40 20 1 7.7 40 40 1 15.7 40 60 1 19.1
40 20 2 8.3 40 40 2 14.3 40 60 2 18.0
40 20 3 9.5 40 40 3 15.9 40 60 3 19.9
;
```

```

PROC GLM DATA=EJEMPL094;
CLASS TEMPERATURA SACAROSA;
MODEL ENERGIA=TEMPERATURA|SACAROSA;

/*Obtención de los coeficientes para caracterizar el
tipo de curvatura*/

DATA EJEMPL094;
SET EJEMPL094;
TL=0;TC=0;
IF TEMPERATURA=20 THEN TL=-1;
IF TEMPERATURA=40 THEN TL=1;
IF TEMPERATURA IN(20,40) THEN TC=1
IF TEMPERATURA=30 THEN TC=-2;
SL=0;SC=0;
IF SACAROSA=20 THEN SL=-1;
IF SACAROSA=60 THEN SL=1;
IF SACAROSA IN(20,60) THEN SC=1;
IF SACAROSA=40 THEN SC=-2;
TLSL=TL*SL; TLSC=TL*SC;
TCSL=TC*SL; TCSC=TC*SC;

/*Análisis de regresión para la caracterización de la
curvatura*/

PROC REG DATA=EJEMPL094;
MODEL ENERGIA=TL TC SL SC TLSL TLSC TCSL TCSC/SS1;

/* Diseño factorial 3^3 */

/* Lectura de los datos del ejemplo 9.6 */

DATA EJEMPL096;
DO DIA=1 TO 3;
  DO OPERADOR=1 TO 3;
    DO CONCENTRACION=1 TO 3;
      DO REPLICA=1 TO 3;
        INPUT RENDIMIENTO @@;OUTPUT;
      END;
    END;
  END;
END;
CARDS;
1.0 1.2 1.7 5.0 4.7 4.2 7.5 6.5 7.7
0.2 0.5 0.7 3.2 3.7 3.5 6.0 6.2 6.2
0.2 0.0 0.3 3.5 3.5 3.2 7.2 6.5 6.7
1.0 0.0 0.5 4.0 3.5 3.5 6.5 6.0 6.2
1.0 0.0 0.0 3.2 3.0 4.0 5.2 5.7 6.5
1.2 0.0 0.5 3.7 4.0 4.2 7.0 6.7 6.8

```

```

1.7  1.2  1.2  4.5  5.0  4.7  6.7  7.5  7.0
0.2  0.7  1.0  3.7  4.0  4.2  7.5  6.0  6.0
0.5  1.0  1.7  3.7  4.5  3.7  6.2  6.5  7.0
;

PROC GLM DATA=EJEMPL096;
CLASS DIA OPERADOR CONCENTRACION;
MODEL RENDIMIENTO=DIA|OPERADOR|CONCENTRACION;

/*Obtención de los coeficientes para caracterizar el
tipo de curvatura*/
DATA EJEMPL096;
SET EJEMPL096;
CL=0;CC=0;
IF CONCENTRACION=1 THEN CL=-1;
IF CONCENTRACION=3 THEN CL=1;
IF CONCENTRACION IN(1,3) THEN CC=1;
IF CONCENTRACION=2 THEN CC=-2;
/*Análisis de varianza para la caracterización de la
curvatura*/

PROC GLM DATA=EJEMPL096;
CLASS DIA OPERADOR;
MODEL RENDIMIENTO=DIA OPERADOR DIA*OPERADOR CL CC DIA*CL
DIA*CC OPERADOR*CL OPERADOR*CC DIA*OPERADOR*CL DIA*OPERADOR*CC;

RUN;

```

9.5. Implementación en R

A partir de los datos de los ejemplos [9.2](#), [9.3](#), [9.4](#) y [9.6](#), se presentan a continuación los programas en el software estadístico R.

```

#####
## Ejemplo 9.2 ##
#####

# Introducción de los datos del ejemplo con n,p,np como los factores de
# un tratamiento
ejemplo9.2<-data.frame(fila=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4))),
col=factor(rep(c(1,2,3,4),4)),trat=factor(c(4,3,2,1,1,2,3,4,3,4,1,2,2,1,
4,3)),peso=c(645,667,670,787,752,637,655,576,642,627,745,675,621,762,596,
660))

anova9.2 <- aov(peso ~ fila+col+trat, data=ejemplo9.2)
summary(lm(anova9.2))
summary(anova9.2)

```

```

# Estimación de los efectos de tratamientos

N<-2603
NP<-2444
NbajoPbajo<-3046
P<-2624
efectoN<-(N+NP-NbajoPbajo-P)/8
efectoP<-(P+NP-NbajoPbajo-N)/8
efectoNP<-(NbajoPbajo+NP-N-P)/8

# Suma de Cuadrados
SCN<-((N+NP-NbajoPbajo-P)^2)/(4*4)
SCP<-((P+NP-NbajoPbajo-N)^2)/(4*4)
SCNP<-((NbajoPbajo+NP-N-P)^2)/(4*4)

# Valores F
CME<-441.6458
FNP<-SCNP/CME
FN<-SCN/CME
FP<-SCP/CME

library(agricolae)

# Prueba LSD de Fisher
LSD.test(anova9.2,"trat", group=TRUE,console=TRUE,main="Tratamiento")

# Prueba de Scheffe
scheffe.test(anova9.2,"trat",group=TRUE,console=TRUE,main="Tratamiento")

# Prueba de Tukey para comparaciones múltiples y el gráfico correspondiente
TukeyHSD(anova9.2,which="trat",ordered=TRUE)
plot(TukeyHSD(anova9.2,which="trat",ordered=TRUE))

## Introducción de los datos del ejemplo con n,p como tratamientos
datos9.2.1<-data.frame(fila=factor(c(rep(1,4),rep(2,4),rep(3,4),rep(4,4))),
  col=factor(rep(c(1,2,3,4),4)),n=c(1,-1,1,-1,-1,1,-1,1,-1,1,-1,1,-1),
  p=c(1,1,-1,-1,-1,-1,1,1,1,1,-1,-1,-1,1,1),peso=c(645,667,670,787,752,
  637,655,576,642,627,745,675,621,762,596,660))

anova9.2.1 <- aov(peso ~ fila+col+n*p, data=datos9.2.1)
summary(anova9.2.1)
summary(lm(anova9.2.1))

lm9.2 = lm (peso ~ fila+col+n+p,data=datos9.2.1)
anova(lm9.2)
summary(lm9.2)
lm9.21 = lm (peso ~ fila+col+n*p,data=datos9.2.1)#estimación de los efectos

```

```

anova(lm9.21)
summary(lm9.21)

#####
## Ejemplo 9.3 ##
#####

# Introducción de los datos
ejemplo9.3<-data.frame(exposic=factor(c(rep(c(rep("EI",6),rep("ED",6)),4))),
pregunta=c(rep(c(rep("PI",12),rep("PII",12)),2)),
clase=factor(c(rep("F",24),rep("S",24))),
replica=factor(rep(c(1,2,3,4,5,6),8)), tporc=c(37.5,37.5,28.1,41.8,33,25.5,
37.5,28.1,37.5,25.5,15.8,30.6,19.5,13.6,31.8,48.2,41.8,24.1,48.2,6.8,28.1,
28.1,35.3,35.3,28.1,25.5,30.6,41.8,39.7,33,22.6,33,35.3,39.7,28.1,25.5,
35.3,51.4,31.8,38.5,19.5,35.3,45,31.8,51.4,41.8,41.8,45))

# Con todas las interacciones dobles y triples entre los factores
anova9.3 <- aov(tporc ~ exposic*pregunta*clase, contrasts=list(exposic=
"contr.sum",pregunta="contr.sum",clase="contr.sum"),data=ejemplo9.3)
summary(anova9.3)

# Para estimar los efectos y hacer el ANOVA
ejemplo9.3$E <- rep(0,48)
ejemplo9.3$E <- ifelse(ejemplo9.3$exposic=='EI',-1,1)
ejemplo9.3$P <- rep(0,48)
ejemplo9.3$P <- ifelse(ejemplo9.3$pregunta=='PI',-1,1)
ejemplo9.3$C <- rep(0,48)
ejemplo9.3$C <- ifelse(ejemplo9.3$clase=='F',-1,1)

lm9.3 <- lm(tporc ~ E*P*C,data=ejemplo9.3)
anova(lm9.3)
summary(lm9.3)

#####
## Ejemplo 9.4 ##
#####

# Introducción de los datos
ejemplo9.4<-data.frame(temperatura=factor(c(rep(20,9),rep(30,9),rep(40,9))),
sacarosa=factor(rep(c(20,40,60),9)),replica=factor(rep(c(1,1,1,2,2,2,3,3,
3),3)),T1S1=factor(c(1,2,3,1,2,3,1,2,3,2,3,1,2,3,1,2,3,1,2,3,1,2,3,1,
2)),T1S2=factor(c(1,2,3,1,2,3,1,2,3,3,1,2,3,1,2,3,1,2,3,1,2,3,1,2,3,1)),
energia=c(3.1,5.5,7.9,3.7,6.7,9.2,4.7,7.3,9.3,6,11.5,17.5,6.9,12.9,15.8,
7.5,13.4,14.7,7.7,15.7,19.1,8.3,14.3,18,9.5,15.9,19.9))

library(Rcmdr)
with(ejemplo9.4, plotMeans(energia, sacarosa, temperatura, error.bars="sd",
connect=TRUE,xlab='Sacarosa',ylab='Energía promedio',main=''))

```

```
interaction.plot(ejemplo9.4$sacarosa,ejemplo9.4$temperatura,
ejemplo9.4$energia,col=1,xlab=' Sacarosa',ylab='Energía
promedio',leg.bty='o',cex=1.5)
```

```
anova9.4 <- aov(energia ~ temperatura*sacarosa,data=ejemplo9.4)
summary(anova9.4)
```

```
lm9.4<-lm(energia~temperatura+sacarosa+temperatura*sacarosa,data=ejemplo9.4)
summary(lm9.4)
anova(lm9.4)
```

```
# Descomposición en dos cuadrados latinos ortogonales para la interacción
```

```
anova9.4.1 <- aov(energia ~ temperatura+sacarosa+T1S1+T1S2,data=ejemplo9.4)
summary(anova9.4.1)
```

```
# Obtención de los coeficientes para caracterizar el tipo de curvatura
```

```
## Para la temperatura
TL <- rep(0,27)
TC <- rep(0,27)
for(i in 1:27)
{
  if(ejemplo9.4$temperatura[i] == 20)
  {TL[i] <- -1 }
  else {
    if(ejemplo9.4$temperatura[i] == 40)
    {TL[i] <- 1 }
  }
  if(ejemplo9.4$temperatura[i] == 20)
  {TC[i] <- 1 }
  else {
    if(ejemplo9.4$temperatura[i] == 30)
    {TC[i] <- -2 }
    else {
      if(ejemplo9.4$temperatura[i] == 40)
      {TC[i] <- 1 }
    }
  }
}
```

```
## Para la Sacarosa
SL <- rep(0,27)
SC <- rep(0,27)
for(i in 1:27)
{
  if(ejemplo9.4$sacarosa[i] == 20)
  {SL[i] <- -1 }
  else {
```

```

if(ejemplo9.4$sacarosa[i] == 60)
{SL[i] <- 1 }
}
if(ejemplo9.4$sacarosa[i] == 20)
{SC[i] <- 1 }
else {
if(ejemplo9.4$sacarosa[i] == 60)
{SC[i] <- 1 }
else {
if(ejemplo9.4$sacarosa[i] == 40)
{SC[i] <- -2 }
}}}

TLSL <- TL*SL
TLSC <- TL*SC
TCSL <- TC*SL
TCSC <- TC*SC

# Análisis de regresión para la caracterización de la curvatura
anova9.4.2<-aov(energia~TL+TC+SL+SC+TLSL+TLSC+TCSL+TCSC,data=ejemplo9.4)
summary(anova9.4.2)

#####
## Ejemplo 9.6 ##
#####

# Introducción de los datos
ejemplo9.6 <- data.frame(dias=factor(c(rep(0,27),rep(1,27),rep(2,27))),
concentracion=factor(c(rep(c(0,0,0,1,1,1,2,2,2),9))),
operador=factor(rep(c(rep(0,9),rep(1,9),rep(2,9)),3)),
rendimiento=c(1.0,1.2,1.7,5.0,4.7,4.2,7.5,6.5,7.7,0.2,0.5,0.7,3.2,3.7,
3.5,6.0,6.2,6.2,0.2,0.0,0.3,3.5,3.5,3.2,7.2,6.5,6.7,1.0,0.0,0.5,4.0,
3.5,3.5,6.5,6.0,6.2,1.0,0.0,0.0,3.2,3.0,4.0,5.2,5.7,6.5,1.2,0.0,0.5,
3.7,4.0,4.2,7.0,6.7,6.8,1.7,1.2,1.2,4.5,5.0,4.7,6.7,7.5,7.0,0.2,0.7,
1.0,3.7,4.0,4.2,7.5,6.0,6.0,0.5,1.0,1.7,3.7,4.5,3.7,6.2,6.5,7.0))

anova9.6 <- aov(rendimiento ~ dias*concentracion*operador,data=ejemplo9.6)
summary(anova9.6)

medias <- model.tables(anova9.6, type = "means")
medias

# Descomposición de las interacciones en cuadrados latinos

D0=(as.numeric(ejemplo9.6$dias)-1+as.numeric(ejemplo9.6$operador)-1)%%3
D02=(as.numeric(ejemplo9.6$dias)-1+2*(as.numeric(ejemplo9.6$operador)-1))%3
D101=factor(ifelse(D0==0,1,ifelse(D0==1,2,3)))
D102=factor(ifelse(D02==0,1,ifelse(D02==1,2,3)))
DC=(as.numeric(ejemplo9.6$dias)-1+as.numeric(ejemplo9.6$concentracion)-1)%%3

```

```

DC2=(as.numeric(ejemplo9.6$dias)-1+
2*(as.numeric(ejemplo9.6$concentracion)-1))%3
D1C1=factor(ifelse(DC==0,1,ifelse(DC==1,2,3)))
D1C2=factor(ifelse(DC2==0,1,ifelse(DC2==1,2,3)))
OC=(as.numeric(ejemplo9.6$operador)-1+
as.numeric(ejemplo9.6$concentracion)-1)%3
OC2=(as.numeric(ejemplo9.6$operador)-1+
2*(as.numeric(ejemplo9.6$concentracion)-1))%3
O1C1=factor(ifelse(OC==0,1,ifelse(OC==1,2,3)))
O1C2=factor(ifelse(OC2==0,1,ifelse(OC2==1,2,3)))

DOC=(as.numeric(ejemplo9.6$dias)-1+as.numeric(ejemplo9.6$operador)-1+
as.numeric(ejemplo9.6$concentracion)-1)%3
DOC2=(as.numeric(ejemplo9.6$dias)-1+(as.numeric(ejemplo9.6$operador)-1)+
2*(as.numeric(ejemplo9.6$concentracion)-1))%3
D02C=(as.numeric(ejemplo9.6$dias)-1+2*(as.numeric(ejemplo9.6$operador)-1)+
(as.numeric(ejemplo9.6$concentracion)-1))%3
D02C2=(as.numeric(ejemplo9.6$dias)-1+2*(as.numeric(ejemplo9.6$operador)-1)+
2*(as.numeric(ejemplo9.6$concentracion)-1))%3
D101C1=factor(ifelse(DOC==0,1,ifelse(DOC==1,2,3)))
D101C2=factor(ifelse(DOC2==0,1,ifelse(DOC2==1,2,3)))
D102C1=factor(ifelse(D02C==0,1,ifelse(D02C==1,2,3)))
D102C2=factor(ifelse(D02C2==0,1,ifelse(D02C2==1,2,3)))

anova9.6.1 <- aov(rendimiento ~ dias+operador+concentracion+D101+D102+D1C1+
D1C2+O1C1+O1C2+D101C1+D101C2+D102C1+D102C2,data=ejemplo9.6)
summary(anova9.6.1)

## Obtención de los coeficientes para caracterizar el tipo de curvatura

CL <- rep(0,81)
CC <- rep(0,81)
for(i in 1:81)
{
if(ejemplo9.6$concentracion[i] == 0)
{CL[i] <- -1 }
else {
if(ejemplo9.6$concentracion[i] == 2)
{CL[i] <- 1 }
}
if(ejemplo9.6$concentracion[i] == 0)
{CC[i] <- 1 }
else {
if(ejemplo9.6$concentracion[i] == 2)
{CC[i] <- 1 }
else {
if(ejemplo9.6$concentracion[i] == 1)
{CC[i] <- -2 }
}}}

```



```
## Análisis de varianza para la caracterización de la curvatura
anova9.6.2 <- aov(rendimiento ~ dias+operador+dias*operador+CL+CC+dias*CL+
dias*CC+operador*CL+operador*CC+dias*operador*CL+dias*operador*CC,
data=ejemplo9.6)
summary(anova9.6.2)
```

9.6. Ejercicios

1. En una zona árida de la Guajira, se quieren ensayar dos tipos de riego (por goteo y por aspersión) sobre el rendimiento del cultivo de ají. A su vez, se quieren probar 3 densidades de plantación: 10, 15 y 20 mil plantas por hectárea. La unidad experimental es una parcela de 30 metros de largo por 6 de ancho. Se tiene dispuesto hacer solo tres repeticiones de cada tratamiento. Hasta donde sea posible, la cantidad de agua suministrada por los dos sistemas será igual y su aplicación se hará periódicamente.
 - a. ¿Qué diseño experimental recomendaría? Justifique su respuesta.
 - b. ¿Cómo asignaría los tratamientos a las unidades experimentales?
 - c. Presente la tabla de análisis de varianza, mostrando solamente las fuentes de variación y los grados de libertad.
 - d. ¿Son los factores cualitativos o cuantitativos?.
 - e. Si el investigador está interesado en conocer la densidad que le produce el máximo rendimiento, ¿qué tiene que hacer?
 - f. ¿Cómo compararía los dos tipos de riego?
2. Suponga un arreglo factorial 2^3 el cual se va a aplicar en un experimento genético en el que se exige que todos los efectos sean aleatorios.
 - a. Presente el modelo apropiado indicando todos los supuestos necesarios.
 - b. Construya la tabla de ANOVA suponiendo r bloques. Obtenga $E(CM)$.
3. En un experimento sobre la aplicación de enmadurecedores en caña de azúcar, se estructuraron 8 bloques con los tratamientos

T_1 : testigo T_2 : polaris T_3 : ethrel.

De cada parcela se recolectaron muestras de caña de azúcar de épocas (0, 2, 4, 6, 8, 10 semanas) después de aplicar el enmadurecedor.

- a. Determine el modelo matemático apropiado para conducir este análisis.
 - b. Realice la tabla de ANOVA, únicamente C de V y gl.
 - c. Desarrolle la prueba para comparar el efecto de dos épocas dentro del mismo tratamiento polaris.
4. Se cree que la adherencia de un pegamento depende de la presión y de la temperatura al ser aplicado. Los datos obtenidos al realizar el experimento son:

Presión ($lb/pulg^2$)	Temperatura ($^{\circ}F$)		
	250	260	270
120	9.60	11.28	9.00
130	9.69	10.10	9.59
140	8.43	11.01	9.03
150	9.98	10.44	9.80

- a. Formule las hipótesis y el modelo lineal para este experimento.
 - b. ¿Se puede analizar si hay interacción entre los factores controlados?
 - c. Analice los datos y obtenga las conclusiones apropiadas.
 - d. Verifique los supuestos sobre los residuos del modelo propuesto.
5. Suponga un diseño factorial 2^4 para este arreglo:
- a. Presente la matriz diseño.
 - b. ¿Cuáles son todos los posibles efectos que se pueden estudiar con este diseño?
 - c. Obtenga el contraste para el efecto principal de D y para el efecto de interacción CD .
 - d. Señale en forma explícita cómo utilizaría los contrastes para calcular los efectos y las sumas de cuadrados.
 - e. ¿Puede darse el caso que el efecto principal A no sea significativo y el efecto de la interacción AB sí lo sea? Justifique su respuesta.
6. En una fábrica de dientes se tiene problemas de calidad: porosidad (burbujas de aire dentro de los dientes), manchas blancas, dientes sucios, dientes quebrados. En los intentos por resolver los problemas se han hecho cambios en algunos factores o variables del proceso. Los factores y niveles son: temperatura de prensado (90, 130 $^{\circ}C$), tiempo de prensado (8 y 15 minutos) y tamaño de la partícula (sin tamizar y

con tamizado), la variable respuesta fue el porcentaje del diente bueno en cada corrida (un lote de producción). Los datos obtenidos son los siguientes:

Temperatura	Tiempo	T. de partícula	% de diente bueno	
90	8	Sin tamizar	76.4	76.2
130	8	Sin tamizar	76.8	76.9
90	15	Sin tamizar	80.4	81.0
130	15	Sin tamizar	77.9	79.6
90	8	Con tamizado	84.4	84.6
130	8	Con tamizado	84.7	84.5
90	15	Con tamizado	82.7	83.2
130	15	Con tamizado	85.0	84.7

- Estime todos los posibles efectos y diga cuáles son significativos.
 - Realice el análisis de varianza de estos datos e interprete los resultados obtenidos.
 - Verifique los supuestos sobre los residuos.
 - ¿Hay un tratamiento “ganador”?
 - ¿Qué condición de proceso sugiere emplear a futuro? Tenga en cuenta, además, que a mayor tiempo y mayor temperatura, más costos.
 - Las condiciones que se utilizaban antes del experimento era temperatura a 130 °C y tiempo a 15 minutos. ¿Por qué cree que se eligieron niveles inferiores de prueba para estos factores?
 - Aunque los resultados parezcan positivos ¿qué se debe hacer para que estos sean suficientes? ¿Explorar más niveles de los factores ya estudiados? ¿Considerar otras causas? ¿Qué otra alternativa sugiere? Justifique su respuesta.
7. Una compañía probó dos métodos químicos para determinar la glucosa en el suero. Se usaron tres recipientes con suero para el experimento, cada uno contenía distintos niveles de glucosa mediante la adición de glucosa al nivel de base. Se prepararon tres muestras de suero cada recipiente, independientes del nivel de glucosa, con cada uno de los dos métodos químicos. Se midió la concentración de glucosa (mg/dl) de todas las muestras en una corrida del espectrómetro. Los resultados fueron:

Método 1			Método 2		
Nivel de glucosa			Nivel de glucosa		
1	2	3	1	2	3
42.5	138.4	180.9	39.8	132.4	176.8
43.3	144.4	180.5	40.3	132.4	173.6
42.9	142.7	183.0	41.2	130.3	174.9

- Escriba el modelo lineal para este experimento, explique cada una de las componentes y haga los supuestos apropiados.
 - Realice el análisis de varianza para los datos y calcule los residuales. ¿Es necesaria una transformación de los datos? Explique.
 - Si es necesaria la transformación, hágala. Realice de nuevo el análisis de varianza y compare los resultados con b.
 - Compruebe la hipótesis nula de no existencia de interacción entre método y glucosa. ¿Cuál es su conclusión? ¿Debe hacerse una prueba para los efectos principales?
 - Compruebe la diferencia entre medias de los métodos para cada nivel de glucosa e interprete los resultados.
8. Se desea investigar de qué manera afecta el tiempo de curado y el tipo de acelerante la resistencia del caucho vulcanizado. Se realizó un experimento, encontrándose los siguientes resultados:

Tiempo de curado	Acelerante ($^{\circ}F$)		
	A	B	C
40	3900	4300	3700
	3600	3700	4100
60	4100	4200	3900
	3500	3900	4000
80	4000	4300	3600
	3800	3600	3800

- Presente una forma como se pudo haber aleatorizado cada una de las 18 unidades experimentales.
- Escriba el modelo lineal para este experimento, explique cada una de las componentes y haga los supuestos apropiados.
- Formule todas las hipótesis que se pueden probar.
- Realice el análisis estadístico apropiado para contrastar las hipótesis planteadas en el ítem anterior.
- En caso de existir efecto de interacción, señale la combinación entre el tiempo de cura y el acelerante que aumenta la resistencia.

- f. Verifique que se cumplan los supuestos sobre los residuos. En caso de no cumplirse el supuesto de igualdad de varianza para tiempo de cura, ¿qué significa eso y qué solución propone?
9. Un científico de suelos realizó un experimento para evaluar una red de resistencias de cuatro electrodos y calcular la electroconductividad (EC) del suelo en celdas conductivas de acrílico especiales. El objetivo del estudio era evaluar la relación entre la EC medida y la salinidad del agua en el suelo con diferentes cantidades de agua. Se incluyeron tres texturas básicas del suelo, ya que la EC es específica de la textura; se usaron dos celdas para cada combinación de tratamiento, los tres tipos de suelo fueron arena arcillosa, arcilla y barro. El agua salina, en tres niveles, se basó en la EC del agua a 2, 8, y 16 dS/m (decisemens/metro) y se establecieron tres niveles de contenido de agua en el suelo, 0, 5 y 15 %. Los siguientes son los valores de EC del suelo determinados con base en las lecturas de la red de cuatro electrodos.

Tipo de Suelo	Salinidad del agua								
	2			8			16		
	Contenido de agua								
	0	5	15	0	5	15	0	5	15
Arena arcillosa	0.60	1.69	3.47	0.05	0.11	0.06	0.07	0.08	0.22
	0.48	2.01	3.30	0.12	0.09	0.19	0.06	0.14	0.17
Arcilla	0.98	2.21	5.68	0.15	0.23	0.40	0.07	0.23	0.43
	0.93	2.48	5.11	0.26	0.35	0.75	0.21	0.35	0.35
Barro	1.37	3.31	5.74	0.72	0.78	2.10	0.40	0.72	1.95
	1.50	2.84	5.38	0.51	1.11	1.18	0.57	0.88	2.87

Fuente: H. Bohn y T. Tabbara, Department of Soil and Water Science, University of Arizona.

- Escriba el modelo lineal para este experimento, explique cada una de las componentes y formule los supuestos apropiados.
- Haga un análisis gráfico de las interacciones y concluya.
- Efectúe el análisis de varianza e interprete los resultados.
- Efectúe comparaciones no planeadas con la finalidad de “escoger el mejor” tratamiento.
- Para las interacciones significativas que involucren factores cuantitativos, realice el análisis de curvatura e interprete los resultados. A continuación se dan los coeficientes polinomiales ortogonales que se pueden usar para calcular las particiones ortogonales, debido a que no hay igual espaciamiento en los factores cuantitativos:

Agua lineal:	-0.617	-0.154	0.772
Agua cuadrática:	0.535	-0.802	0.267
Salinidad lineal:	-0.671	-0.067	0.738
Salinidad cuadrática:	0.465	-0.814	0.349

- f. Valide los supuestos realizados sobre el modelo propuesto en el numeral anterior.

10. Suponga un diseño en BCA con arreglo factorial 3^3 :

- Presente el modelo para analizar este experimento.
- Realice el análisis de varianza para el modelo propuesto en a.
- ¿Cómo obtiene en forma explícita SC(ABC) y cuál es el estimador de su varianza?

11. En un factorial 3^2 en BCA si los errores, ϵ_{ijk} , son independientes e idénticamente distribuidos como normal $(0, \sigma^2)$ un contraste entre efectos de tratamientos, por ejemplo,

$$L = \sum_i \sum_j \lambda_{ij} \tau_{ij}$$

es estimado por

$$\hat{L} = \sum_i \sum_j \lambda_{ij} \bar{y}_{ij}.$$

- ¿Cómo se distribuye $\hat{L}$? Presente los parámetros necesarios.
- Si $\sigma^2 = 1$, ¿qué se tiene en particular?
- Si $\hat{L}$ se distribuye normal, ¿cómo se distribuye $\frac{Z^2 \sigma^2}{S^2}$?, donde Z es una normal estándar.

12. Muestre que en un factorial $p \times q$ con r repeticiones se satisface

$$\begin{aligned} & \sum_{i=1}^r \sum_{j=1}^p \sum_{k=1}^q [(\bar{y}_{.j.} - \bar{y}_{...}) + (\bar{y}_{..k} - \bar{y}_{...}) + (\bar{y}_{.jk} - \bar{y}_{.j.} - \bar{y}_{..k} - \bar{y}_{...}) \\ & \quad + (\bar{y}_{ijk} - \bar{y}_{.jk})]^2 = r q \sum_{j=1}^p (\bar{y}_{.j.} - \bar{y}_{...})^2 + r p \sum_{k=1}^q (\bar{y}_{..k} - \bar{y}_{...})^2 \\ & \quad + r \sum_{j=1}^p \sum_{k=1}^q (\bar{y}_{.jk} - \bar{y}_{.j.} - \bar{y}_{..k} - \bar{y}_{...})^2 + \sum_{i=1}^r \sum_{j=1}^p \sum_{k=1}^q (y_{ijk} - \bar{y}_{.jk})^2. \end{aligned}$$

9.7. Anexo

A continuación se presenta la teoría que sirve de base para el desarrollo y comprensión de los resultados en arreglos factoriales.

9.7.1. Ideas básicas sobre congruencia

Definición 9.1. Sean a y $b \in \mathbb{Z}$, con $a \neq 0$. Se dice que “ a divide a b ” si

$$\exists X \in \mathbb{Z}, \text{ de modo que } b = Xa, \text{ y se denota por } (a/b).$$

Un algoritmo de división es: si $a \in \mathbb{Z}$, $b \in \mathbb{Z}^*$, existe $z, s \in \mathbb{Z}$, tal que $a = zb + s$, donde s es el residuo, $s \in (0, b)$.

Definición 9.2. (Congruencia módulo p) Se dice que dos enteros a y b son congruentes módulo p , $p \in \mathbb{Z}$, si y solamente si $a - b \in \mathbb{Z}$ se denota $a \equiv b(p)$.

Propiedades de la Congruencia

Sean a, b, c y p enteros, con $p > 0$ se satisfacen las siguientes propiedades:

- i. $a \equiv a(p)$ (reflexiva).
- ii. Si $a \equiv b(p)$, entonces $b \equiv a(p)$ (simétrica).
- iii. Si $a \equiv b(p)$ y $b \equiv c(p)$, entonces $a \equiv c(p)$ (transitiva).
- iv. Si $ca \equiv cb(p)$, con c y p primos relativos, entonces $a \equiv b(p)$.

Definición 9.3. De las propiedades i., ii. y iii., se puede decir que la congruencia módulo p define una relación de equivalencia sobre $\mathbb{Z}$. Además, esta relación de equivalencia define una partición de $\mathbb{Z}$ en p clases de equivalencia llamadas *clases residuales módulo p* .

Ejemplo 9.7. Todos los residuos que se obtienen al dividir por 7 y dan residuo $[r]$ son:

	$\mathbb{Z}$	$p = 7$
R		
E	$[0]$	$= \{0, 7, 14, \dots\}$
S	$[1]$	$= \{1, 8, 15, \dots\}$
I	$[2]$	$= \{2, 9, 16, \dots\}$
D	$[3]$	$= \{3, 10, 17, \dots\}$
U	$[4]$	$= \{4, 11, 18, \dots\}$
O	$[5]$	$= \{5, 12, 19, \dots\}$
S	$[6]$	$= \{6, 13, 20, \dots\}$

Sea J_p el conjunto de todos los residuales módulo p . En este caso,

$$J_p = [0], [1], [2], \dots, [p-1]$$

Si $[i]$ y $[j]$ son elementos de J_p , entonces

$$[i] + [j] = [i + j]$$

es elemento de J_p . Por ejemplo, $[4] + [6] = [6 + 4] = [10] = [3]$ módulo 7.

Observación 9.2. Cuando los resultados no caen dentro de los residuos, entonces debe tomarse la suma en módulo p .

Propiedades

Sean $[i]$, $[j]$ y $[k]$ elementos de J_p :

- i. $[i] + [j] = [j] + [i]$.
- ii. $([i] + [j]) + [k] = [i] + ([j] + [k])$.
- iii. $[0] + [i] = [i] + [0] = [i]$.
- iv. $[i][j] = [j][i]$.
- v. $([i] + [j])[k] = [i][k] + [j][k]$.
- vi. $[i][i] = [i][i] = [i]$.
- vii. $([i][j])[k] = [i]([j][k])$.

Una descomposición general que es útil para cualquier tipo de factores, es decir, que permite fácilmente la aplicación de los principios de confusión y construcción de factoriales, es la que se basa en la teoría de grupos. Esta teoría permite obtener particiones ortogonales de los efectos de tratamientos.

Por la importancia de esta teoría en la obtención de grupos ortogonales, en este capítulo se hace una breve presentación de esta, la cual es aplicable a los factoriales 2^k y factoriales del tipo p^k , con p un número primo o potencia de primo.

9.7.2. Breve introducción a conceptos básicos de teoría de grupos

Un grupo G es un conjunto no vacío de elementos $a, b, c, \dots$ para los cuales se define una operación binaria (para dos elementos) que satisface los siguientes axiomas:

1. Si $a, b \in G$, existe un único elemento $c \in G$ tal que $a \circ b = c$.
2. Si $a \in G$, existe un elemento identidad $e \in G$ tal que $a * e = e * a = a$.
3. La operación binaria es asociativa, esto es, si $a, b, c \in G$

$$(a \circ b) \circ c = a \circ (b \circ c).$$

4. Para cada elemento $a \in G$ existe un inverso único a^{-1} tal que $a \circ a^{-1} = e$.

Definición 9.4. Un grupo G es finito si el número de elementos en G es finito y el número de elementos se llama el orden de G . Un grupo G se llama *conmutativo o abeliano* si $a \circ b = b \circ a, \forall a, b \in G$.

Definición 9.5. Un subconjunto S de un grupo G es un *subgrupo* si S a su vez es un grupo que satisface los cuatro axiomas para la operación binaria.

Observación 9.3.

- a. Si $G = J_p$, entonces $(G; \circ)$ no es grupo.
- b. Si $G = J_p$ y p no es primo, entonces $(G, \circ)$ no tiene estructura de grupo.
- c. Si $G = J_p$ y p es primo, entonces $(G, \circ)$ tiene estructura de *grupo abeliano*.

Definición 9.6. Un grupo G se dice que forma un *anillo* si en G están definidos $(+)$, $(\circ)$ que satisfacen:

- a. G es un grupo abeliano para $(+)$.
- b. Si $a, b \in G$, entonces $a \circ b \in G$.
- c. Si $a, b, y c \in G$, entonces $(a \circ b) \circ c = a \circ (b \circ c)$.
- d. $a, b, y c \in G$, entonces $a \circ (b + c) = a \circ b + a \circ c$.

Definición 9.7. Si G es un anillo conmutativo¹, entonces $a \in G$ se dice que es un *divisor de cero* si existe $b \in G, (b \neq 0)$ tal que $ab = 0$.

Ejemplo 9.8. $J_6 = \{0, 1, \dots, 5\}$, entonces $[2][3] = [6] = [0]$ en el módulo G .

¹Si en un anillo G se cumple la propiedad conmutativa, entonces se dice que G es un anillo conmutativo.

Observación 9.4. Si p es primo no hay división por cero. Por ejemplo, J_7 no tiene división por cero.

Dos grupos G y G' son *isomórficos* si existe una transformación o mapeo uno a uno $a \rightarrow a'$ de G sobre G' , tal que $(a \cdot b)' = (a' \cdot b')$. Este mapeo se llama un isomorfismo de G sobre G' . Así, bajo un isomorfismo es indiferente el orden en el cual se aplique la operación binaria y la transformación, esto es, si se quiere la imagen de $(a \cdot b)$ en G' , se puede encontrar directamente la imagen de a y la de b por separado y sobre ello aplicar la operación en G' . El isomorfismo indica que los dos grupos tienen la misma estructura.

Para los factoriales 3^k se usa la definición de los tres totales que definen un determinado efecto. Para ejemplificar estas ideas, considere un factorial 3^3 donde los 27 tratamientos se representan por (i, j, k) , con $i, j, k = 0, 1, 2$.

El efecto principal de A es la variación entre los totales $(A)_0$, $(A)_1$ y $(A)_2$. $(A)_0$ es un subgrupo del grupo de 27 tratamientos. En dicho grupo, la operación binaria queda definida por:

$$(ijk) + (i'j'k') = ([i + i']_{\text{mód } 3} \quad [j + j']_{\text{mód } 3} \quad [k + k']_{\text{mód } 3}).$$

Así, $(A)_0$ se define por $A_{i=0} \pmod{3}$ y constituye el total de los nueve tratamientos (000), (001), (010), (011), (020), (002), (022), (012) y (021). Estos nueve tratamientos son el subgrupo intrabloque de A . Algunos ejemplos de la operación binaria son:

$$\begin{aligned}(000) + (022) &= (022)_{\text{mód } 3} \\ (012) + (021) &= (033)_{\text{mód } 3} = (000)_{\text{mód } 3} \\ (011) + (021) &= (032)_{\text{mód } 3} = (002)_{\text{mód } 3}.\end{aligned}$$

El total $(A)_1$ se define por $A_{i=1} \pmod{3}$ y se obtiene sumando mód 3 a i en el subgrupo de nueve tratamientos. El total $(A)_2$ se define por $A_{i=2} \pmod{3}$ y se obtiene sumando mód 3 a i en el subgrupo intrabloque A , estos resultados se muestran en el siguiente arreglo:

$(A)_0$	$(A)_1$	$(A)_2$
000	100	200
010	110	211
020	120	220
001	101	201
011	111	211
021	121	221
002	102	202
012	112	212
022	122	222

De manera semejante para los otros efectos principales. Una interacción entre dos factores a tres niveles cada uno puede descomponerse en cuatro contrastes lineal $\times$ lineal ($A_l B_l$), lineal $\times$ cuadrático ($A_l B_c$), cuadrático $\times$ lineal ($A_c B_l$) y cuadrático $\times$ cuadrático ($A_c B_c$), interpretando, así, los cuatro grados de libertad de la interacción. Sin embargo, si los factores son cualitativos, o uno de ellos lo es, esta interpretación pierde sentido (en este caso deben hacerse tablas de contrastes). Una descomposición más general se lleva a cabo usando la teoría de grupos, en la que se forman dos conjuntos de tres totales, cada uno con dos gl en cada conjunto. Así, el efecto de interacción es la falta de uniformidad de los tres totales en cada uno de los dos subconjuntos. Usando el factorial 3^3 con factores A , B y C , la interacción de A con B se estudia como sigue:

Subgrupo intrabloque $A^1 B^1$		
$(AB)_{i+j=0} \pmod{3}$	$(AB)_{i+j=1} \pmod{3}$	$(AB)_{i+j=2} \pmod{3}$
$(A^1 B^1)_0$	$(A^1 B^1)_1$	$(A^1 B^1)_2$
000	100	200
120	220	020
210	010	110
001	101	201
121	221	021
211	011	111
002	102	202
122	222	022
212	012	112

Nótese que basta sumar 1 a i (mód 3) para pasar de $(AB)_0$ a $(AB)_1$ y de $(AB)_1$ a $(AB)_2$.

La variabilidad entre los tres totales $(A^1 B^1)_0$, $(A^1 B^1)_1$ y $(A^1 B^1)_2$ representa dos grados de libertad de la interacción entre A y B . Los otros dos grados de libertad se generan al considerar la variación entre los totales de los tres subconjuntos siguientes:

Subgrupo intrabloque $A^1 B^2$		
$(AB)_{i+2j=0} \pmod{3}$	$(AB)_{i+2j=1} \pmod{3}$	$(AB)_{i+2j=2} \pmod{3}$
$(A^1 B^2)_0$	$(A^1 B^2)_1$	$(A^1 B^2)_2$
000	100	200
110	210	010
220	020	120
001	101	201
111	211	011
221	021	121
002	102	202
112	212	012
222	022	122



Capítulo *diez*

Confusión en experimentos factoriales

10.1. Introducción

Los diseños factoriales 2^k y 3^k son de gran importancia práctica tanto en estudios exploratorios como confirmatorios. Estos arreglos se emplean ampliamente en los estudios de investigación como un medio para tratar los efectos de varios factores de tratamiento en forma simultánea en el mismo experimento. Los factoriales 2^k y 3^k tienen k factores a dos y tres niveles, respectivamente. Conforme el número de factores aumenta el número de combinaciones de tratamientos aumenta con rapidez. Cuando esto sucede se debe hacer uso de los diseños en bloques incompletos para controlar el error experimental.

El uso de bloques incompletos para garantizar homogeneidad dentro de las unidades experimentales cuando hay arreglos con muchos tratamientos obliga a hacer uso de las siguientes técnicas de reducción del tamaño:

- i. Confusión, para garantizar homogeneidad.
- ii. Replicación fraccionada, con el fin de disminuir costos en el experimento.

El principio de confusión tiene su base en el hecho de que ciertas interacciones de poca importancia se pueden sacrificar, de manera que la imprecisión resultante del uso de bloques grandes y heterogéneos se concentra en esas interacciones (las confundidas) en vez de afectar el resto de los efectos e interacciones que son de mayor interés para la investigación.

El principio de confusión consiste en formar bloques incompletos de tal modo que los efectos de interés sean ortogonales respecto a bloques y que algunos efectos o interacciones de poco interés práctico queden confundidos con bloques. La idea original de este análisis fue propuesta por Yates (1934).

De esta manera, la *confusión* es una técnica de diseño mediante la cual un experimento factorial completo se distribuye en bloques, donde el tamaño del bloque es menor que el número de combinaciones de los tratamientos de una réplica.

La confusión hace uso de la teoría de bloque generador, grupos y campos de Galois (ver anexo 9.7.2), puesto que los tratamientos que forman un bloque se determinan con base en estos desarrollos matemáticos, los cuales permiten obtener bloques ortogonales.

Las siguientes definiciones son importantes para el entendimiento de los resultados presentados a lo largo de este capítulo.

Definición 10.1. Se llama *réplica* del experimento a un conjunto de bloques en el cual están todos los tratamientos una sola vez.

Definición 10.2. Si un efecto está confundido en todas las réplicas, se dice que hay *confusión total*. Aquí necesariamente hay sacrificio de efectos principales o interacciones, que fueron confundidos con bloques.

Definición 10.3. Cuando un efecto o interacción se confunde con bloques en algunas replicaciones, se dice que hay *confusión parcial*. En este caso, se tiene información de todo el conjunto de tratamientos en el arreglo factorial.

En algunas áreas de la experimentación, como en la agronomía, biología e industria, se pueden tener varios tamaños de UE. Si un bloque es una UE más grande con error experimental mayor que las UE que lo constituyen, se podrían estudiar efectos totalmente confundidos, aunque con menor grado de precisión respecto a los otros.

Definición 10.4. Las variaciones que se consideran entre bloques se denominan *error interbloque*. Al error que proviene de la variación entre UE dentro de bloques se le llama *error intrabloque*.

Las interacciones entre dos factores se llaman de primer orden, las de tres factores se llaman de segundo orden y así sucesivamente.

Para la conformación de los bloques, conviene confundir los efectos que no interese estudiar o que no tengan interés práctico en la investigación. Como las interacciones de orden superior por lo general son negligibles, estas deben ser confundidas con los bloques. Además, en el caso de experimentos con muchos factores, los efectos principales, las interacciones de dos factores y otras interacciones de menor orden son los efectos de mayor interés. Al confundir las interacciones de orden más alto, los demás efectos se estiman sin penalización.

Una justificación al hecho anterior está amparada por la serie de expansión de Taylor. En este caso, si y es la característica en estudio, la cual está en función de los niveles de los factores, es decir $f(a, b, c, \dots)$, al expandir en series de Taylor, esta función puede ser escrita como:

$$y = f(a, b, c, \dots) = \mu + (\alpha_1 a + \beta_1 b + \gamma_1 c + \dots) + (\alpha_2 a^2 + \beta_2 b^2 + \gamma_2 c^2 + \dots) + (\alpha\beta)_{11}ab + (\alpha\gamma)_{11}ac + \dots + e,$$

donde μ es el valor medio de los factores, $\alpha_1 a + \beta_1 b + \gamma_1 c + \dots$ es la magnitud de los efectos lineales y en $(\alpha_2 a^2 + \beta_2 b^2 + \gamma_2 c^2 + \dots) + (\alpha\beta)_{11}ab + (\alpha\gamma)_{11}ac + \dots$ se tienen los efectos cuadráticos y todas las interacciones de primer, segundo, $\dots$, orden.

Finalmente, se tiene un residuo cuyo valor depende de la aproximación que se requiera al verdadero valor y , como los residuos convergen a cero es

claro que en valor absoluto cada término de orden superior que se agrega a la expansión en la serie es cada vez menor.

Puede observarse que si el desarrollo en serie del valor de y incluye solamente los efectos lineales, tal consideración conduce a una primera aproximación del valor con la característica en estudio. Un mayor refinamiento se produce cuando se incluyen los efectos cuadráticos y las interacciones de segundo orden, tercer orden, etc.

Como en los experimentos factoriales 2^k no es posible estimar efectos cuadráticos, los efectos lineales son de hecho los factores principales, el término dentro de los paréntesis contendría las interacciones de dos factores, de tres factores, etc. De ahí, es evidente considerar más importantes los efectos principales de los factores que las interacciones de primer orden, estas últimas más importantes que las de segundo orden, y así sucesivamente.

10.2. Confusión en series 2^k

En esta sección, se considera la construcción y el análisis del sistema factorial 2^k en 2^p bloques incompletos, donde $p < k$. Estos diseños pueden correrse en dos bloques, en cuatro bloques, en ocho o más bloques, según los criterios de confusión.

10.2.1. Confusión del diseño factorial 2^k en dos bloques

Para una mayor comprensión de este procedimiento, se ilustra con un diseño factorial 2^3 . Si en este arreglo bloques de ocho UE homogéneos no son factibles, se puede trabajar con bloques de cuatro UE que sí sean homogéneos. De esta forma, los tratamientos se asignarán a los bloques según el siguiente esquema:

Bloque I		Bloque II	
a	100	(1)	000
b	010	ab	110
c	001	ac	101
abc	111	bc	011
$(ABC)_{i+j+k=1}$		$(ABC)_{i+j+k=0}$	

El esquema anterior se llama un *esquema básico*, este se replica R -veces, generando $2R$ bloques y aleatorizando los tratamientos en los bloques. El modelo usual es el de bloques aleatorizados está dado por:

$$y_{sl} = \mu + \tau_s + \delta_l + e_{sl}, \quad (10.1)$$

con $s = 1, \dots, t$, $l = 1, \dots, 2R$, donde μ , τ_s y δ_l son los efectos de la media, tratamientos (descompuestos en efectos principales e interacciones) y bloques, respectivamente.

El anterior modelo se puede expresar como

$$y_{ijkl} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \gamma_k + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + \delta_l + e_{ijkl}. \quad (10.2)$$

En términos de (10.1),

$$\tau_s = \alpha_i + \beta_j + (\alpha\beta)_{ij} + \gamma_k + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk}, \quad i, j, k = 0, 1, l = 1, 2, \dots, 2R.$$

Otra forma adicional de presentar el modelo (10.1) es

$$y_{ijkhd} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \gamma_k + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + \eta_h + \omega_{d(h)} + e_{ijkhd}, \quad (10.3)$$

donde $\delta_l = \eta_h + \omega_{d(h)}$ con $h = 1, 2, \dots, R$ y $d = 1, 2$.

La variación entre $A_{i=0}$ y $A_{i=1}$ es la misma que se tendría sin efecto de bloques. Por lo tanto, el factor A se estima como

$$\begin{aligned} \hat{A} &= \frac{1}{4R} [110 + 101 + 100 + 111 - 000 - 010 - 001 - 011]_{\text{mód } 2} \\ &= \frac{1}{4R} [A_{i=1} - A_{i=0}]_{\text{mód } 2}, \end{aligned}$$

es decir, la estimación del factor A no se ve afectada por el hecho de tener bloques incompletos. El estimador de A es ortogonal a bloques, en el sentido de que dos tratamientos en el bloque I tienen signo negativo y dos tratamientos tienen signo positivo, lo mismo sucede con el bloque II. Por lo tanto, el estimador de A no contiene efectos aditivos de bloques.

De igual manera, B y C son ortogonales con ABC y, en consecuencia, con los bloques. Para ilustrar la ortogonalidad con las interacciones de dos factores, se considera la interacción AB :

$$SC(AB) = \frac{[(AB)_{i+j=0}]^2 + [(AB)_{i+j=1}]^2}{4R} - \frac{y_{\dots}^2}{8R},$$

con $(AB)_{i+j=0} = (000 + 110 + 001 + 111)$ y $(AB)_{i+j=1} = (100 + 010 + 101 + 011)$. En estos totales se tienen $2 \sum_{l=1}^{2R} \delta_l$, entonces no se afectará la variabilidad entre los totales $(AB)_0$ y $(AB)_1$, ya que ambos se ven incrementados por $2 \sum_{l=1}^{2R} \delta_l$.

De igual forma, resultarán ortogonales con bloques las interacciones AC y BC . La confusión se ve claramente al considerar los totales que miden el efecto ABC , es decir,

$$\begin{aligned}
\widehat{ABC} &= \frac{1}{4R} [100 + 010 + 001 + 111 - 000 - 110 - 101 - 011] \\
&= \frac{1}{4R} [a + b + c + abc - (1) - ab - ac - bc] \\
&= \frac{1}{4R} [(ABC)_{i+j+k=1} - (ABC)_{i+j+k=0}],
\end{aligned}$$

y el estimador de la diferencia entre bloques es:

$$\widehat{Bloques} = \frac{1}{4R} \left[\sum bloques_1 - \sum bloques_2 \right].$$

Las estimaciones en las dos anteriores expresiones coinciden, lo cual muestra que el efecto de la interacción triple ABC queda confundido con el bloque en el modelo (10.2). La varianza de estimación de cualquiera de los efectos factoriales es $\frac{1}{2R}(\sigma^2)'$.

Nota. Si el experimento se planea en bloques completamente aleatorizados, todos los efectos factoriales serían estimables, y la varianza de estimación de cualquiera de ellos sería $\frac{\sigma^2}{2R}$, donde σ^2 es la varianza por UE cuando el experimento es DBCA.

Si $(\sigma^2)' \geq \sigma^2$, la eficiencia relativa (ER) de estimación del DBI contra el DBCA, se define por el cociente

$$ER = \frac{(\sigma^2)'}{\sigma^2}.$$

En general, se tiene mayor precisión de estimación en DBI a causa de la disminución de la varianza intrabloque (dentro de bloques); al tener en cada bloque menos UE's, entonces es más homogéneo. Sin embargo, debe tenerse claro que así sean más eficientes los bloques incompletos conducen a cierta pérdida de información en relación con los efectos factoriales de interés.

Las sumas de cuadrados se calculan de la manera usual para el análisis de varianza excepto que se excluye la partición de la suma de cuadrados para el efecto de interacción confundido con los bloques. La suma de cuadrados del bloque incluirá el efecto factorial confundido.

Las fuentes de variación y los grados de libertad para el análisis de varianza en el factorial 2^3 con 2 bloques incompletos en cada una de las R réplicas se presentan en la tabla 10.1. Como ABC se confunde con los bloques, la suma de cuadrados para los bloques incluye el efecto ABC .

Usualmente, la variación entre bloques no se descompone, como se indica en la tabla 10.1. Sin embargo, en algunos casos se requiere tener información sobre la interacción ABC , aunque con mucha menos precisión que sin usar

la confusión. Así, se descomponen los grados de libertad y las sumas de cuadrados de bloques en la forma indicada en dicha tabla. La SCE interbloque se obtiene por diferencia, esto es,

$$SCE(\text{interbloque}) = SC(\text{Bloques}) - SC(\text{Réplicas}) - SC(ABC).$$

El error interbloque es el que se genera por la variación entre bloques dentro de réplicas. Esta descomposición casi no se usa, excepto cuando se confunden efectos principales generando el llamado arreglo en parcelas divididas, diseño que se discute con mayor detalle en el capítulo 11.

Tabla 10.1: Análisis de varianza para un factorial 2^3 con $b = 2$ bloques incompletos en cada una de los R grupos de réplicas

C. de V.	gl
Bloques	$2R - 1$
Réplicas	$R - 1$
Bloques(réplicas)	$R(b - 1) = R$
ABC	1
Error interbloque	
Réplica $\times$ ABC	$R - 1$
Tratamientos	6
A	1
B	1
AB	1
C	1
AC	1
BC	1
Error intrabloque	$6(R - 1)$
Total	$8R - 1$

Ejemplo 10.1. Una investigación busca mejorar la pureza de un producto químico, para ello se involucra la influencia de tres factores: tasa de agitación (A), concentración del compuesto base (B) y concentración del reactivo (C). El químico estableció un experimento con un diseño factorial con factores a dos niveles para un arreglo factorial 2^3 .

Se realizaron tres réplicas del experimento, pero solo se podían realizar cuatro corridas del proceso químico cada día. Esto llevó a que cada réplica debía correrse en dos días diferentes (bloques).

En la conducción del experimento, se construyó un diseño de bloques incompletos confundiendo la interacción de orden tres ABC con los bloques. En este caso, el contraste de definición es $L = x_1 + x_2 + x_3$ y el diseño se ilustra en la figura 10.1.

En la figura 10.1, $\circ$ representa las corridas con $(ABC)_0$ y $\bullet$ las corridas con $(ABC)_1$. Las combinaciones de tratamientos dentro de cada bloque se muestran en la tabla 10.2.




Figura 10.1: Vista geométrica del diseño factorial 2^k en dos bloques.

Tabla 10.2: Arreglo de tratamientos para la pureza observada de un producto químico en un factorial 2^3 confundido totalmente

Réplica I		Réplica II		Réplica III	
Bloque 1 (ABC) ₁	Bloque 2 (ABC) ₀	Bloque 3 (ABC) ₀	Bloque 4 (ABC) ₁	Bloque 5 (ABC) ₀	Bloque 6 (ABC) ₁
001 : 44.5	000 : 46.8	101 : 49.8	001 : 55.5	011 : 53.2	100 : 69.5
010 : 44.2	011 : 44.5	110 : 52.0	100 : 59.8	101 : 57.2	010 : 62.8
100 : 60.1	101 : 57.0	011 : 48.8	010 : 56.0	000 : 56.0	001 : 55.0
111 : 48.8	110 : 58.5	000 : 51.5	111 : 58.5	110 : 59.0	111 : 53.8

En este experimento, se tienen dos pasos en el proceso de la aleatorización:

- Decidir qué bloques llevan $(ABC)_0$ y qué bloques llevan $(ABC)_1$.
- Decidir la aleatorización de los tratamientos dentro de cada bloque.

Con los datos presentados en la tabla 10.2 se realiza el análisis de varianza usual. El efecto de tratamientos se descompone en seis contrastes ortogonales que representan los efectos principales y las interacciones, como se muestra en la tabla 10.3.

Al utilizar los totales de las combinaciones de los tratamientos que se muestran en la tabla 10.3, los efectos de los factores pueden estimarse como en un diseño 2^k , usando los procedimientos presentados en el capítulo 9.

El efecto del bloque confundido con la interacción ABC se calcula por la diferencia en la respuesta promedio entre los dos bloques, a través de todas las réplicas.

$$\begin{aligned}
 \text{Efecto del bloque} &= \bar{y}_{\text{Bloque 1}} - \bar{y}_{\text{Bloque 2}} = \frac{1}{12}(ABC_1 - ABC_0) = \widehat{ABC} \\
 &= \frac{1}{12}(668.5 - 634.3) = 2.85
 \end{aligned}$$

Tabla 10.3: Arreglo de signos para el diseño del ejemplo 10.1

Efecto	Totales de tratamiento								$\Sigma +$	$\Sigma -$
	000	001	010	011	100	101	110	111		
Total	154.3	155.0	163.0	146.5	189.4	164.0	169.5	161.1	1302.8	
<i>A</i>	+	+	+	+	+	+	+	+	684.0	618.8
<i>B</i>	-	-	+	+	-	-	+	+	640.1	662.7
<i>AB</i>	+	+	-	-	-	-	+	+	639.9	662.9
<i>C</i>	-	+	-	+	-	+	-	+	626.6	676.2
<i>AC</i>	+	-	+	-	-	+	-	+	642.4	660.4
<i>BC</i>	+	-	-	+	+	-	-	+	651.3	651.5
<i>ABC</i>	-	+	+	-	+	-	-	+	668.5	634.3

En la tabla 10.4, se resume el análisis de varianza de este experimento. Las sumas de cuadrados de cada uno de los efectos no confundidos se obtienen con los resultados del capítulo 9, estos fueron los siguientes:

$$\begin{aligned}
 SC(\text{Bloques}) &= \sum_{l=1}^B \frac{B_l^2}{2^{k-1}} - \frac{y_{\dots}^2}{2^k R} \\
 &= \frac{197.6^2 + 206.8^2 + 202.1^2 + 229.8^2 + 225.4^2 + 241.1^2}{4} \\
 &\quad - \frac{1302.8^2}{24} = 379.38 \\
 SC(\text{Répli}) &= \sum_{h=1}^R \frac{R_h^2}{2^k} - \frac{y_{\dots}^2}{2^k R} \\
 &= \frac{404.4^2 + 431.9^2 + 466.5^2}{8} - \frac{1302.8^2}{24} = 242.08 \\
 SC(\text{Bloque}(\text{Répli})) &= \sum_{h=1}^R \left(\sum_{d=1}^b \frac{y_{\dots h d}^2}{2^{k-1}} - \frac{y_{\dots h.}^2}{2^k} \right) \\
 &= \frac{197.6^2 + 206.8^2}{4} - \frac{404.4^2}{8} + \frac{202.1^2 + 229.8^2}{4} - \frac{431.9^2}{8} \\
 &\quad + \frac{225.4^2 + 241.1^2}{4} - \frac{466.5^2}{8} = 137.30 \\
 SC(ABC) &= 2^2(3)(2.85)^2 = 48.74 \\
 SC(\text{Répli} \times ABC) &= SC(\text{Bloque}) - SC(\text{Répli}) - SC(ABC) \\
 &= SC(\text{Bloque}(\text{Répli})) - SC(ABC) = 88.57 \\
 SCT_{CM} &= 44.5^2 + 44.2^2 + \dots + 53.8^2 - \frac{1302.8^2}{24} = 893.63.
 \end{aligned}$$

A partir de los resultados obtenidos en la tabla 10.4, se concluye que hay diferencias entre los bloques al igual que entre los tratamientos. Esta última es causada únicamente por el efecto que los factores tasa de agitación (A) y concentración del reactivo (C) tienen sobre la pureza del producto químico; los demás efectos principales e interacciones no son significativos. Adicionalmente, las diferencias que se ocasionan en la pureza se ven influenciadas en mayor medida, por la diferencia que hay entre los niveles de la tasa de agitación que por los niveles de concentración del reactivo.

Tabla 10.4: Análisis de varianza para los datos de la pureza de un producto químico en un factorial 2^3 confundido totalmente

C. de V.	gl	SC	CM	F
Bloques	5	379.38	75.88	5.12
Réplicas	2	242.08	121.04	
Bloques(réplicas)	3	137.30	45.77	
ABC	1	48.74	48.74	
Error interbloque				
Réplica $\times$ ABC	2	88.57	44.28	
Tratamientos	6	336.46	56.08	3.78
A	1	177.13	177.13	11.95
B	1	21.28	21.28	1.44
AB	1	22.04	22.04	1.49
C	1	102.51	102.51	6.92
AC	1	13.50	13.50	0.91
BC	1	0.002	0.002	0.00
Error intrabloque	12	177.80	14.82	
Total	23	893.63		

10.2.2. Confusión del diseño factorial 2^k en cuatro bloques

Es posible construir diseños factoriales 2^k confundido en cuatro bloques con 2^{k-2} observaciones cada uno. Estos diseños son particularmente útiles en situaciones en las que el número de factores es moderadamente grande, por ejemplo $k \geq 4$, y el tamaño de los bloques es relativamente pequeño.

Como ejemplo para ilustrar el procedimiento, considérese el diseño factorial 2^4 . Si cada bloque incluye únicamente cuatro tratamientos, entonces deben utilizarse cuatro bloques. La construcción de este diseño es relativamente simple. Si, por ejemplo, se confunde con el efecto de bloque las interacciones ABC y BCD, estos efectos tienen dos contrastes de definición asociados con ellos

$$L_1 = x_1 + x_2 + x_3$$

$$L_2 = x_2 + x_3 + x_4.$$

El total de tratamientos se presenta en la tabla 10.5, a partir de la cual se genera la primera combinación de tratamientos, que queda asignada al primer bloque (bloque generador).

Tabla 10.5: Total de tratamientos en un diseño 2^3

A	B	C	D		$(ABC)_0$	$(BCD)_0$	$(AD)_0$
0	0	0	0	(1)	•	*	✓
0	0	0	1	d	•		
0	0	1	0	c			
0	1	0	0	b			
0	0	1	1	cd		*	
0	1	0	1	bd		*	
0	1	1	0	bc	•	*	✓
0	1	1	1	bcd	•		
1	0	0	0	a		*	
1	0	0	1	ad			
1	0	1	0	ac	•		
1	1	0	0	ab	•		
1	0	1	1	acd	•	*	✓
1	1	0	1	abd	•	*	✓
1	1	1	0	abc		*	
1	1	1	1	$abcd$			

donde • : $(ABC)_0 \pmod 2$, * : $(BCD)_0 \pmod 2$ y ✓ : $(AD)_0 \pmod 2$.

Observando cuidadosamente se encuentra que hay otro efecto además de ABC y BCD confundido con los bloques. Puesto que hay tres bloques con tres grados de libertad entre ellos, ABC y BCD tienen un solo grado de libertad, es evidente la necesidad de confundir un efecto adicional con un grado de libertad. Este efecto es la *interacción generalizada* de ABC y BCD , la cual se define como el producto de ABC y BCD módulo 2, es decir, $(ABC)(BCD) = AB^2C^2D = AD$ o, equivalentemente, $(x_1 + x_2 + x_3)(x_2 + x_3 + x_4) = x_1 + x_4 \pmod 2$, donde $x_1 + x_4$ representa a AD , interacción que también está confundida con los bloques.

La interacción $(ABC)_0(BCD)_0 = (AD)_0$ constituye el subgrupo intra-bloque. En este caso, lo conforman los tratamientos (1), bc , abd , acd . Este subgrupo satisface todas las condiciones de grupo matemático. Así, por ejemplo, $bc \cdot abd = ab^2cd = acd$ es un elemento del propio grupo. Además, el recíproco de abd es abd , pues $abd \cdot abd = (1)$.

En la tabla 10.6 se muestra el diseño completo 2^4 en cuatro bloques. En esta tabla se muestra cómo quedan asignados los diferentes tratamientos a los bloques.

Tabla 10.6: El diseño 2^4 en cuatro bloques con ABC , BCD y AD confundidos

Bloque	ABC	BCD	Tratamientos			
1	–	–	(1)	acd	bc	abd
2	–	+	ab	ac	d	bcd
3	+	–	a	abc	bd	cd
4	+	+	b	c	ad	$abcd$

O, en forma equivalente, la tabla 10.6 se representa también de la siguiente manera:

Bloque 1	Bloque 2	Bloque 3	Bloque 4
(1)	ab	a	b
acd	ac	abd	c
bc	d	bd	ad
abd	bcd	cd	$abcd$
$(ABC)_0$	$(ABC)_0$	$(ABC)_1$	$(ABC)_1$
$(BCD)_0$	$(BCD)_1$	$(BCD)_0$	$(BCD)_1$
$(AD)_0$	$(AD)_1$	$(AD)_1$	$(AD)_0$

La estructura anterior de confusión se puede replicar R veces, obteniendo un sistema de confusión total.

Los elementos del subgrupo intrabloque tienen una particularidad: si se multiplica por los elementos adecuados de acuerdo con las reglas del grupo generado, se construye el resto de los bloques. Siguiendo con el ejemplo,

Bloque 1	Bloque 2	Bloque 3	Bloque 4
(1)	$(1) \cdot ab = ab$	$(1) \cdot a = a$	$(1) \cdot b = b$
bc	$bc \cdot ab = ac$	$bc \cdot a = abc$	$bc \cdot b = c$
abd	$abd \cdot ab = d$	$abd \cdot a = bd$	$abd \cdot b = ad$
acd	$acd \cdot ab = bcd$	$acd \cdot a = cd$	$acd \cdot b = abcd$

La comparación de los totales de tratamientos de los bloques 1 y 4 con los totales de los bloques 2 y 3 es precisamente el estimador del efecto total debido a la interacción AD .

En la práctica, el bloque principal puede obtenerse a partir de la definición de contrastes y de la propiedad de la teoría de grupos, y los demás bloques pueden determinarse a partir de estas combinaciones de los tratamientos aplicando el método presentado anteriormente.

10.2.3. Confusión del diseño factorial 2^k en 2^p bloques

Los métodos descritos anteriormente pueden extenderse a la construcción de un diseño factorial 2^k confundido en 2^p bloques ($p < k$), donde cada

bloque contiene exactamente 2^{k-p} tratamientos. Se seleccionan p efectos que van a confundirse con los bloques. Los bloques pueden generarse mediante el uso de las p definiciones de contrastes $L_1, L_2, \dots, L_p$ asociadas con estos efectos. Cuando esto sucede, se tienen $2^p - p - 1$ interacciones generalizadas confundidas con los bloques. Se debe tener cuidado al seleccionar los efectos que se confunden para que no se sacrifique información sobre los efectos que pueden ser de interés para el investigador.

El análisis estadístico de estos diseños es similar al presentado en el caso de un diseño 2^{3-1} que se presentó en las secciones anteriores. Las sumas de cuadrados de todos los efectos se calculan como si no se hubiera realizado el bloqueo, en tanto que la suma de cuadrados de los bloques se encuentra adicionando las diferentes sumas de cuadrados de todos los efectos confundidos con los bloques, bien sea que se tenga un sistema de confusión parcial o uno total.

Observación 10.1. En un esquema de confusión donde no se requiere confundir los efectos principales y las interacciones de segundo orden, es necesario que $k \leq 2^{k-p} - 1$.

10.3. Confusión en series 3^k

Al igual que en los arreglos 2^k en los diseños experimentales 3^k es un poco difícil la realización de los 3^k tratamientos en condiciones uniformes, esto nuevamente conlleva a que se realice un plan de confusión con bloques. El diseño 3^k puede confundirse en 3^p bloques incompletos, donde $p < k$. Por consiguiente, estos diseños pueden confundirse en tres bloques, nueve bloques, y así sucesivamente.

10.3.1. Confusión del diseño factorial 3^k en tres bloques

Suponga que se quiere confundir el diseño 3^k en tres bloques incompletos. Estos tres bloques tienen dos grados de libertad entre ellos, por lo cual, hay dos grados de libertad confundidos con los bloques (debido a dos efectos y/o interacciones). Además, cada interacción doble tiene cuatro grados de libertad y puede descomponerse en dos componentes de la interacción (por ejemplo, A^1B^1 y A^1B^2), cada una con dos grados de libertad; cada interacción de tres factores tiene ocho grados de libertad y puede descomponerse en cuatro componentes de la interacción ($A^1B^1C^1$, $A^1B^1C^2$, $A^1B^2C^1$ y $A^1B^2C^2$), cada

una con dos grados de libertad, y así sucesivamente. Esto hace conveniente confundir un componente de interacción de orden superior con los bloques.

Para la construcción de los bloques, se parte del contraste de definición

$$L = \alpha_1 x_1 + \alpha_2 x_2 + \cdots + \alpha_k x_k,$$

donde α_i ($i = 1, \dots, k$) representa el exponente del factor i -ésimo en el efecto que va a confundirse y x_i hace referencia al nivel del factor i -ésimo en una combinación de tratamientos en particular. Para la serie 3^k , se tiene $\alpha_i = 0, 1, 2$, donde la primera α_i diferente de cero es la unidad y $x_i = 0$ (nivel bajo), 1 (nivel intermedio) ó 2 (nivel alto). Las combinaciones de tratamientos del diseño 3^k se asignan a los bloques con base en el valor de la combinación L (mód 3). Las combinaciones de tratamientos que satisfacen $L = 0$ (mód 3) constituyen el *bloque principal* (bloque generador). Por conveniencia, este bloque debe incluir siempre el tratamiento $00 \dots 0$.

Para ilustrar el procedimiento, considere un factorial 3^2 con tres bloques, los efectos en este caso son A, B, A^1B^1 y A^1B^2 . Si se quiere confundir con bloques el efecto A^1B^2 , se obtiene la definición de contrastes $L = x_1 + 2x_2$.

Con esta definición, la distribución de tratamientos tiene el siguiente arreglo:

Bloque 1	Bloque 2	Bloque 3
00	10	20
11	21	01
22	02	12
$(A^1B^2)_{i+2j=0}$	$(A^1B^2)_{i+2j=1}$	$(A^1B^2)_{i+2j=2}$

Estos tres bloques forman una réplica. Con bloques de tres tratamientos se puede tener más seguridad al suponer el efecto del bloque constante que con bloques de nueve tratamientos, lo que conlleva a una reducción del error experimental.

Al observar que los tres niveles de A y B están en cada uno de los bloques, se puede asegurar la ortogonalidad de A y B con A^1B^2 , es decir, con los bloques. Esto es, los tres totales que miden el efecto del factor A y los tres que miden el efecto de B se verán afectados de igual manera por los bloques, de tal modo que su variabilidad no se altera. Esto mismo sucede con el efecto A^1B^1 , sus totales son:

$$(A^1B^1)_0 = (00+21+12), (A^1B^1)_1 = (10+01+22) \text{ y } (A^1B^1)_2 = (20+11+02).$$

Como se puede ver, los bloques están igualmente representados en cada total, por lo que su variabilidad no se altera. Esto quiere decir que si se pudieran tener bloques de nueve UE's homogéneas, los totales para los efectos

A , B y A^1B^1 serían diferentes; el cambio sería la suma de una constante para todos, por lo que su variabilidad sería la misma con los bloques de tres UE's con el efecto confundido A^1B^2 .

Si el esquema de confusión básico se repite en las diferentes réplicas, se tendrá un sistema de confusión total. En este caso, como se está confundiendo A^1B^2 en todas las réplicas se tiene este tipo de confusión.

Ejemplo 10.2. Considere el ejemplo 9.1, en el cual se evalúa la energía consumida por las abejas al beber, para determinar el efecto de la temperatura del ambiente y la viscosidad del líquido en el consumo de energía. Suponga, en este caso, que el investigador decidió confundir el efecto T^1S^2 con la finalidad de homogeneizar las UE. El modelo propuesto para este conjunto de datos es:

$$y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{i+j} + \delta_{i+2j} + \epsilon_{ijk}, \quad \text{mód } 3$$

con $i, j = 0, 1, 2$ y $k = 1, 2, 3$, donde y_{ijk} hace referencia a la energía gastada por las abejas cuando se someten a la i -ésima temperatura j -ésima concentración de sacarosa y k -ésima réplica, α_i hace referencia al efecto de la i -ésima temperatura, β_j el efecto de la j -ésima concentración de sacarosa, $(\alpha\beta)_{i+j}$ es el efecto de interacción entre temperatura y concentración de sacarosa y δ_k es el efecto del bloque.

En el ejemplo 9.1, se encontraron las siguientes sumas de cuadrados de los efectos $SC(T) = 293.16$, $SC(S) = 309.96$, $SC(T^1S^1) = 13.73$, $SCT_{CM} = 646.53$, $SC(\text{Bloque}) = SC(T^1S^2) = 13.40$ y $SCE = 16.28$.

Con base en la información anterior, se obtiene la tabla 10.7 de análisis de varianza. De la tabla se concluye que hay efecto de la interacción entre temperatura y la sacarosa, ya que $F = 7.58 > F_{(2,18,0.05)} = 3.55$. Este resultado es el mismo que se había obtenido con el factorial completo.

Tabla 10.7: Resultados del ANOVA para los datos del ejemplo 9.1 al confundir el efecto T^1S^2

C. de V.	gl	SC	CM	F
Bloque(T^1S^2)	2	13.40	6.70	
Tratamiento	6	616.85	102.81	113.60
Temperatura (T)	2	293.16	146.58	162.00
Sacarosa (S)	2	309.96	154.98	171.28
T^1S^1	2	13.73	6.86	7.58
Error	18	16.28	0.905	
Total	26	646.53		

10.3.2. Confusión del diseño factorial 3^k en nueve bloques

En algunas situaciones experimentales se hace necesario confundir en un diseño 3^k arreglos con nueve bloques, cuando esto sucede, se tiene que ocho grados de libertad van a estar confundidos con los bloques. Para construir estos diseños se eligen dos componentes de interacción (L_1, L_2) y, como resultado, dos más se confundirán automáticamente produciendo los ocho grados de libertad requeridos. Las dos últimas componentes son las interacciones generalizadas de los efectos elegidos originalmente.

Las dos componentes de interacción elegidas inicialmente producen dos definiciones de contrastes

$$\begin{aligned} L_1 &= \alpha_1 x_1 + \alpha_2 x_2 + \cdots + \alpha_k x_k = 0, 1, 2 \quad (\text{mód } 3) \\ L_2 &= \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k = 0, 1, 2 \quad (\text{mód } 3), \end{aligned}$$

donde α_i y β_j son los exponentes de las primeras y la segundas interacciones generalizadas, respectivamente, con la condición de que los primeros α_i y β_j diferentes de cero son la unidad. Las combinaciones de tratamientos que tienen el mismo par de valores para (L_1, L_2) se asignan al mismo bloque.

El bloque principal consta de las combinaciones de tratamientos que satisfacen $L_1 = L_2 = 0$ (mód 3). Los elementos de este bloque forman un grupo respecto a la adición módulo 3.

Como un ejemplo, considere el diseño factorial 3^5 confundido en nueve bloques con 27 tratamientos cada uno. Suponga que se elige confundir $B^1 C^2 D^1$ y $A^1 D^1 E^2$ y sus interacciones generalizadas. Confundidas con bloques son:

$$\begin{aligned} (B^1 C^2 D^1)(A^1 D^1 E^2) &= A^1 B^1 C^2 D^2 E^2 \\ (B^1 C^2 D^1)(A^1 D^1 E^2)^2 &= A^2 B^1 C^2 D^3 E^4 = A^2 B^1 C^2 E^1 \\ &= (A^2 B^1 C^2 E^1)^2 = A^1 B^2 C^1 E^2. \end{aligned}$$

Para las interacciones a confundir ($B^1 C^2 D^1$ y $A^1 D^1 E^2$) se encuentran las siguientes definiciones de contrastes:

$$\begin{aligned} L_1 &= x_2 + 2x_3 + x_4 \\ L_2 &= x_1 + x_4 + 2x_5. \end{aligned}$$

Los nueve bloques se construyen utilizando estas definiciones de contrastes y la propiedad de la teoría de grupos a partir del bloque principal o bloque generador.

Para el diseño 3^k en nueve bloques, habrá cuatro componentes de interacción confundidos; los demás componentes de estas interacciones que no están confundidos pueden determinarse restando la suma de cuadrados del componente confundido de la suma de cuadrados de la interacción completa.

10.3.3. Confusión del diseño factorial 3^k en 3^s bloques

El diseño factorial 3^k puede confundirse en 3^s bloques con 3^{k-s} ($s < k$) unidades experimentales cada uno. El procedimiento consiste en seleccionar s efectos independientes que habrán de confundirse con los bloques. Como resultado, exactamente otros $(3^s - 2s - 1)/2$ efectos se confunden de manera automática. Estos efectos son las interacciones generalizadas de los efectos elegidos originalmente.

Como ilustración, considere un diseño 3^5 que se confunde en 27 bloques. Puesto que $s = 3$, se seleccionarían tres componentes de interacción independientes, lo cual conlleva a que automáticamente se confunda otros $[3^3 - 2(3) - 1]/2 = 10$ interacciones (conocidas como interacciones generalizadas). Suponga que se eligen $A^1C^1D^2E^1$, $B^1C^1D^2E^2$ y $A^1B^2C^1$. A partir de estos efectos pueden construirse tres definiciones de contrastes, y los 27 bloques se generan con los métodos descritos anteriormente. Los otros 10 efectos confundidos con los bloques son:

$$\begin{aligned}
 (A^1C^1D^2E^1)(B^1C^1D^2E^2) &= A^1B^1C^2D^1 \\
 (A^1C^1D^2E^1)(B^1C^1D^2E^2)^2 &= A^1B^2C^3D^6E^5 = A^1B^2E^2 \\
 (A^1C^1D^2E^1)(A^1B^2C^1) &= A^2B^2C^2D^2E^1 = A^1B^1C^1D^1E^2 \\
 (A^1C^1D^2E^1)(A^1B^2C^1)^2 &= A^3B^4C^3D^2E^1 = B^1E^1 \\
 (B^1C^1D^2E^2)(A^1B^2C^1) &= A^1B^3C^2D^2E^2 \\
 (B^1C^1D^2E^2)(A^1B^2C^1)^2 &= A^2B^5C^3D^2E^2 = A^1B^1D^1E^1 \\
 (A^1C^1D^2E^1)(B^1C^1D^2E^2)(A^1B^2C^1) &= A^2B^3C^3D^4E^3 = A^1D^2 \\
 (A^1C^1D^2E^1)^2(B^1C^1D^2E^2)(A^1B^2C^1) &= A^3B^3C^4D^6E^4 = C^1E^1 \\
 (A^1C^1D^2E^1)(B^1C^1D^2E^2)^2(A^1B^2C^1) &= A^2B^4C^4D^6E^5 = A^1B^2C^2E^1 \\
 (A^1C^1D^2E^1)(B^1C^1D^2E^2)(A^1B^2C^1)^2 &= A^3B^5C^4D^4E^3 = B^1C^2D^2.
 \end{aligned}$$

Se trata de un diseño que requiere $3^5 = 243$ tratamientos, dispuestos en 27 bloques con 9 tratamientos cada uno para conformar una réplica del experimento.

10.4. Confusión en series p^k

Si p es primo o potencia de primo, el uso de los campos de Galois en p permitirá confundir con bloques los efectos deseados en factoriales p^k . La confusión generalizará bloques de p^s UE, con $s < k$.

Si $k - s = 1$ solo se confunde un efecto. Si se tiene $k - s = 2$, se confunden dos efectos y las interacciones generalizadas, y así sucesivamente.

Las interacciones generalizadas entre dos efectos en un factorial p^k serán $(p - 1)$ efectos; así, si X y Y son efectos originales, sus interacciones generalizadas serán:

$$XY, XY^2, XY^3, \dots, XY^{p-1}.$$

Todas las potencias resultantes se evalúan con campos de Galois en p . Este proceso continuará si $k - s < 2$, el número de interacciones confundidas es grande.

El siguiente teorema generaliza los resultados presentados en los diseños factoriales con confusión 2^k y 3^k presentados en las secciones anteriores.

Teorema 10.1. *Fisher (1945) propuso el siguiente teorema de confusión mínima en factoriales p^k . Un esquema factorial p^k se puede arreglar con p^{k-s} bloques de p^s UEs cada uno sin confundir efectos principales ni interacciones de dos factores si $k \leq \frac{p^s - 1}{p - 1}$.*

El teorema se usa para generar diseños con confusión total o parcial de interacciones de tres o más factores. La construcción de esos diseños es relativamente fácil, partiendo de las ecuaciones del tipo $L = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_k x_k = 0, 1, 2, \dots, p - 1$, con los α_i 's y las x_i 's en el campo de Galois en p . El mejor procedimiento es considerar un factorial p^s completo para definir los s niveles de p factores con una parte de su interacción no confundida. Se van generando los valores de otros niveles uno a uno, usando las ecuaciones que definen los efectos confundidos también uno por uno.

Como hasta el momento se ha enfocado la confusión de un diseño factorial a un sistema de confusión total. En la siguiente sección se presenta la confusión parcial y la utilidad funcional de la misma en un diseño experimental.

10.5. Confusión Parcial

Si se va a establecer una réplica completa del experimento y se desea usar confusión, no es necesario sacrificar por completo la información sobre efectos o interacciones que entran en el plan de confusión; se puede planear un

arreglo en que en algunas replicaciones estén confundidos unos efectos y en otras estén otros. Esto último se hace con la finalidad de realizar inferencias sobre cada uno de los factores principales e interacciones involucradas en el diseño.

Para ilustrar el procedimiento de confusión parcial, considere la alternativa que se presenta en la tabla 10.8. En este caso, hay cuatro réplicas del diseño 2^3 , pero en cada réplica se ha confundido una interacción diferente. Por ejemplo, ABC está confundido en la réplica I, BC en la réplica II y AC en la réplica III. Como resultado puede obtenerse información de ABC a partir de los datos de las réplicas II y III; información de AC puede obtenerse de las réplicas I y III; información de BC puede obtenerse de las réplicas I y II. Para estos efectos, se obtiene información de dos terceras partes de la información de las interacciones porque no están confundidas en dos réplicas.

Tabla 10.8: Confusión parcial en un diseño factorial 2^3

Réplica I		Réplica II		Réplica III	
Bloque 1	Bloque 2	Bloque 3	Bloque 4	Bloque 5	Bloque 6
(1)	a	(1)	b	(1)	a
ab	b	a	c	b	c
ac	c	bc	ab	ac	ab
bc	abc	abc	ac	abc	bc
$(ABC)_0$	$(ABC)_1$	$(BC)_0$	$(BC)_1$	$(AC)_0$	$(AC)_1$

El esquema de cálculo para la estimación de los efectos es el siguiente:

Efectos	Estimados en réplicas	No. efectivo
A	I, II y III	3
B	I, II y III	3
AB	I, II y III	3
C	I, II y III	3
AC	I y II	2
BC	I y III	2
ABC	II y III	2

En la tabla 10.9 se presenta el análisis de varianza para este diseño. Para calcular las sumas de cuadrados de las interacciones, solo se deben usar los datos de las réplicas en las que no está confundida una interacción, como se evidencia en la tabla 10.9. La suma de cuadrados del error está conformada por las sumas de cuadrados de réplicas $\times$ sumas de cuadrados del efecto principal, más las sumas de cuadrados de réplicas $\times$ sumas de cuadrados de interacción para cada réplica, en la que esa interacción no está confundida (por ejemplo, réplicas $\times ABC$ para las réplicas II y III). Los grados de libertad (gl)

para bloques se descomponen en gl para las réplicas y gl de bloques dentro de réplicas.

Tabla 10.9: Análisis de varianza de un diseño 2^3 parcialmente confundido

C de V	gl
Bloques	$Rb - 1 = 5$
Réplicas	$R - 1 = 2$
Bloques dentro de réplicas	$(b - 1)R = 3$
[ABC (rép. I)+ BC (rép. II)+ AC (rép. III)]	
Tratamientos	7
<i>A</i>	1
<i>B</i>	1
<i>AB</i>	1
<i>C</i>	1
<i>AC</i> (réplicas I y II)	1
<i>BC</i> (réplicas I y III)	1
<i>ABC</i> (réplicas II y III)	1
Error	11
Total	23

En general,

$$SC(\text{Répli}) = \frac{1}{2^k} \sum_{h=1}^R R_h^2 - \frac{T^2}{2^k R}$$

$$SC(\text{Bloque}(\text{Répli})) = \sum_{h=1}^R \left(\sum_{d=1}^b \frac{y_{\dots hd}^2}{2^{k-1}} - \frac{y_{\dots h.}^2}{2^k} \right),$$

donde R_h es el total de la h -ésima réplica, es decir, los efectos no están confundidos.

La suma de cuadrados para bloques se obtiene como

$$SC(\text{Bloques}) = \frac{1}{4} \sum_{i=1}^6 B_i^2 - \frac{T^2}{24},$$

donde B_i es el total del i -ésimo bloque y T es el gran total.

Se puede obtener la $SC(\text{Bloques}_{ajustada})$ para saber si el efecto del bloque es significativo o no, para esto se usa como estadístico de prueba el cociente entre $CM(\text{Bloques}_{ajustada})$ y el CME .

Ejemplo 10.3. Se estudió bajo invernadero dos tipos de suelo (b_0 : con arena y b_1 : con estiércol) y dos niveles humedad (c_0 : suelo seco y c_1 : suelo húmedo) en los rendimientos de paja de dos variedades de soya (a_0 y a_1) Méndez (1993). Para la realización de este experimento, se usó un esquema de confusión parcial de las interacciones, como se presenta en la tabla 10.10.

Tabla 10.10: Rendimientos de la paja en un experimento de invernadero con confusión parcial

Réplica I				Réplica II			
Bloque 1		Bloque 2		Bloque 3		Bloque 4	
$(BC)_0$		$(BC)_1$		$(AB)_0$		$(AB)_1$	
(000)	7	(010)	24	(110)	36	(011)	31
(111)	39	(101)	31	(000)	19	(101)	36
(100)	30	(001)	21	(111)	41	(010)	30
(011)	27	(110)	39	(001)	30	(100)	33

Réplica III				Réplica IV			
Bloque 5		Bloque 6		Bloque 7		Bloque 8	
$(AC)_1$		$(AC)_0$		$(ABC)_1$		$(ABC)_0$	
(100)	28	(101)	31	(111)	66	(000)	11
(001)	24	(010)	19	(100)	31	(011)	29
(110)	35	(000)	13	(001)	21	(101)	33
(011)	26	(111)	36	(010)	25	(110)	43

Las sumas de cuadrados de A , B y C pueden calcularse de la manera usual, utilizando las 32 observaciones. Sin embargo, $SC(AB)$ debe encontrarse utilizando únicamente los datos de las réplicas I, III y IV; la $SC(AC)$ con las réplicas I, II y IV; la $SC(BC)$ con las réplicas II, III y IV; y la $SC(ABC)$ con las réplicas I, II y III.

Por consiguiente, las sumas de cuadrados se obtienen de modo usual (a partir de la tabla de contrastes) para los efectos principales, es decir,

$$SC(A) = \frac{231^2}{4(8)} = 1667.53$$

$$SC(B) = \frac{147^2}{4(8)} = 675.28$$

$$SC(C) = \frac{99^2}{4(8)} = 306.28.$$

En la tabla 10.11, se muestran los efectos ajustados. Esto se refiere a las interacciones y el ajuste consiste en eliminar del efecto no ajustado la diferencia o efecto en la réplica, donde cada interacción está confundida. Por ejemplo,

$$(AB)' = (AB)_0 - (AB)_1 - [(AB)_0 - (AB)_1]_{II} = 481 - 464 - (126 - 130) = 21,$$

donde $(AB)'$ denota confusión parcial. Este efecto puede ser también calculado directamente de las réplicas en las que no este confundido.

$$(AB)' = (106 - 12) + (108 - 104) + (141 - 118) = 355 - 334 = 21.$$

Tabla 10.11: Totales por tratamiento y efectos principales e interacciones

Trato	000	001	010	011	100	101	110	111	$\Sigma +$	$\Sigma -$	Sin ajus.	Ajus.
Total	50	96	98	113	122	131	153	182				
Tratos.												
<i>A</i>	-	-	-	-	+	+	+	+	588	357	231	231
<i>B</i>	-	-	+	+	-	-	+	+	546	399	147	147
<i>AB</i>	+	+	-	-	-	-	+	+	481	464	17	
									355	334		21
<i>C</i>	-	+	-	+	-	+	-	+	522	423	99	99
<i>AC</i>	+	-	+	-	-	+	-	+	461	484	-23	
									362	371		-9
<i>BC</i>	+	-	-	+	+	-	-	+	467	478	-11	
									364	363		1
<i>ABC</i>	-	+	+	-	+	-	-	+	493	447	51	
									355	331		24
Total	+	+	+	+	+	+	+	+	945	945	945	945

De igual manera, se hace para $(AC)'$, $(BC)'$ y $(ABC)'$ que son -9 , 1 y 24 , respectivamente. Para las sumas de cuadrados hay que modificar los divisores, ya que estas estimaciones provienen de menos observaciones; así,

$$SC(AB)' = \frac{21^2}{3(8)} = 18.38, \quad SC(AC)' = \frac{(-9)^2}{3(8)} = 3.38,$$

$$SC(BC)' = \frac{1^2}{24} = 0.04, \quad SC(ABC)' = \frac{24^2}{24} = 24.$$

En las anteriores sumas de cuadrados solamente se tienen en cuenta las tres réplicas en que no está confundido el efecto.

La suma de cuadrados para bloques es:

$$SC(\text{Bloques}) = \frac{1}{4} \sum_{i=1}^8 B_i^2 - \frac{T^2}{32}$$

$$= \frac{1}{4}(103^2 + 115^2 + \cdots + 116^2) - \frac{945^2}{32} = 364.2.$$

La anterior suma de cuadrados puede descomponerse en la suma de cuadrados de réplica y suma de cuadrados de bloques dentro réplica, como se muestra a continuación:

$$SC(\text{Répli}) = \frac{1}{8} \sum_{h=1}^4 R_h^2 - \frac{T^2}{32}$$

$$= \frac{1}{8}(218^2 + 256^2 + 212^2 + 259^2) - \frac{945^2}{32} = 228.6$$

$$\begin{aligned} SC(Bloque(Répli)) &= \sum_{h=1}^4 \left(\sum_{d=1}^2 \frac{y_{...hd}^2}{2^{k-1}} - \frac{y_{...h.}^2}{2^k} \right) \\ &= \frac{103^2 + 115^2}{4} - \frac{218^2}{8} + \dots + \frac{143^2 + 116^2}{4} - \frac{259^2}{8} \\ &= 135.6. \end{aligned}$$

Los anteriores resultados se resumen en la tabla 10.12 de análisis de varianza. Según estos resultados, solo los efectos principales son significativos. Una observación de los signos y de los efectos en la tabla 10.11 es suficiente para interpretar dichos efectos.

Tabla 10.12: Análisis de varianza para los rendimientos de paja al aplicar confusión parcial

C de V	GL	SC	CM	F
Bloques	7	364.20	52.03	
Réplicas	3	228.6	76.2	
Bloque(réplica)	4	135.6	33.9	
Tratos ajustados por bloques	7	2694.88		
A	1	1667.53	1667.53	51.83
B	1	675.28	675.28	20.99
AB (réplicas I, III y IV)	1'	18.37	18.37	0.57
C	1	306.28	306.28	9.52
AC (réplicas I, II y IV)	1'	3.38	3.38	0.10
BC (réplicas II, III y IV)	1'	0.04	0.04	0.00
ABC (réplicas I, II y III)	1'	24.00	24.00	0.74
Error(intrabloque)	17'	546.87	32.17	
Total	31	3605.95		

Se pueden confundir con bloques varios efectos al mismo tiempo. Esto debe hacerse cuando hay muchos tratamientos y los tamaños de los bloques son pequeños. En los factoriales 3^k , lo más conveniente es la confusión parcial de los componentes de las interacciones de alto orden. Como un ejemplo considere un factorial 3^3 sin confusión, se requieren bloques de 27 tratamientos. En la mayoría de las aplicaciones, es difícil conseguir grupos de 27 tratamientos homogéneos que funcionen como bloques. Confundiendo un efecto con bloques, se puede usar bloques de 9 tratamientos, en los que ya es más factible la homogeneidad de las UE's dentro del bloque.

Como la interacción ABC con 8 grados de libertad se descompone en efectos $A^1B^1C^1$, $A^1B^1C^2$, $A^1B^2C^1$ y $A^1B^2C^2$ con 2 grados de libertad cada uno, estos se pueden descomponer cada uno en una repetición. Sin embargo,

se puede tener menos de 4 réplicas y, entonces, solo se confundirán 2 ó 3 efectos que forman la interacción triple ABC .

10.6. Confusión en experimentos factoriales asimétricos

En algunas aplicaciones prácticas son frecuentemente usados los factoriales asimétricos. Se puede tener dos o tres grupos de factores en que todos los factores en el mismo grupo tienen el mismo número de niveles. En particular son de interés los experimentos $2^m \times 3^q$, es decir, m factores con dos niveles cada uno y q factores con tres niveles cada uno. Esta clase de factoriales ha sido usada y promovida por Taguchi (1986), Taguchi (1987) y Roy (1990) en diseños de control de calidad para detectar puntos fuera de control, para lo cual es de gran importancia aplicar los factoriales fraccionados en diseños $2^m \times 3^q$.

La construcción de fracciones irregulares y del sistema de confusión es similar al presentado en las secciones anteriores para los arreglos 2^k y 3^k . La idea para la construcción de los diferentes bloques consiste en combinar los sistemas de confusión de los diseños factoriales 2^k y 3^k .

Cuando se quiere usar los métodos para la construcción del sistema de confusión descritos en las secciones anteriores, se debe conformar bloques de tamaño $2^p 3^s$, con $p \leq m$ y $s \leq q$. La idea general es combinar un sistema de confusión en el factorial 2^m con el factorial completo 3^q , o un sistema de confusión en el factorial 3^q con el factorial completo 2^m o, haciendo uso de una tercera posibilidad, combinar los sistemas de confusión de los dos factoriales. Con el propósito de ilustrar el procedimiento, a continuación se propone un diseño factorial $2^2 \times 3^2$ con bloques de tamaño 18, 12 y 6.

Se denotan las combinaciones de los tratamientos con (x_1, x_2, z_1, z_2) , donde $x_1, x_2 = 0, 1$ (mód 2) representan los niveles del factorial 2^2 con factores A y B , y $z_1, z_2 = 0, 1, 2$ (mód 3) los del factorial 3^2 con factores C y D . Además, sea S_i el i -ésimo conjunto de tratamientos para un sistema de confusión en el factorial 2^2 y S'_j el j -ésimo conjunto del sistema de confusión de tratamientos para el factorial 3^2 . Combinando los conjuntos S_i y S'_j en un arreglo apropiado se conforma el sistema de confusión del factorial $2^2 \times 3^2$. Estos sistemas se describen brevemente a continuación.

Bloques de tamaño 18

Confundiendo AB en bloques de tamaño dos, se obtiene $S_1 = \{(0, 0), (1, 1)\}$, $S_2 = \{(1, 0)(0, 1)\}$. Al combinar este factorial confundido con el

diseño factorial completo 3^2 , donde $S' = \{(0, 0), (1, 0), (2, 0), (0, 1), (1, 1), (2, 1), (0, 2), (1, 2), (2, 2)\}$, entonces se obtienen los bloques S_1S' y S_2S' . Esto quiere decir que se unieron todas las combinaciones de tratamientos en S_i ($i = 1, 2$) con todas combinaciones de tratamientos en S' , quedando dos conjuntos o bloques con 18 tratamientos cada uno, (x_1, x_2, z_1, z_2) . Estos dos bloques forman el arreglo básico, el cual puede ser replicado R veces. Excepto por la interacción AB (con un grado de libertad), los efectos principales A, B, C, D y todas las otras interacciones, es decir, CD, ABC, ABD, ACD, BCD y $ABCD$, son estimables.

Una alternativa para replicar el arreglo básico es usar confusión parcial de A, B y AB . En este caso, se tiene información parcial sobre estos tres efectos e información completa sobre los otros efectos.

Bloques de tamaño 12

El diseño es obtenido generando tres conjuntos S'_1, S'_2, S'_3 al confundir CD , los cuales son: $S'_1 = \{(0, 0), (1, 2), (2, 1)\}$, $S'_2 = \{(1, 0), (0, 1), (2, 2)\}$ y $S'_3 = \{(2, 0), (0, 2), (1, 1)\}$. Al igual que en el caso anterior, al combinar este factorial confundido con el factorial completo 2^2 , donde $S = \{(0, 0), (1, 0), (0, 1), (1, 1)\}$. Se forman tres bloques SS'_1, SS'_2 y SS'_3 con 12 tratamientos cada uno. Este arreglo básico necesita ser replicado R veces. Alternativamente, algunos sistemas de confusión parcial para el factorial 3^2 pueden usarse, de tal manera que la información sobre todos los efectos principales e interacción sea factible de estimar.

Bloques de tamaño 6

Se combinan los sistemas de confusión para los dos factoriales 2^2 y 3^2 . Una posibilidad es confundir AB , generando $S_1 = \{(0, 0), (1, 1)\}$ y $S_2 = \{(1, 0), (0, 1)\}$, y confundir CD , generando $S'_1 = \{(0, 0), (1, 2), (2, 1)\}$, $S'_2 = \{(1, 0), (0, 1), (2, 2)\}$ y $S'_3 = \{(2, 0), (0, 2), (1, 1)\}$. Las seis combinaciones $S_iS'_j$ ($i = 1, 2, j = 1, 2, 3$) generan seis bloques con seis tratamientos cada uno. Nótese que al confundir AB y CD la interacción generalizada $ABCD$ también es confundida con los bloques. Obviamente, existen otras posibilidades de formar S_i y S'_j y varios sistemas de confusión parcial que pueden usarse para obtener la cantidad deseada de información sobre los efectos principales e interacciones.

Observación 10.2. El método presentado anteriormente es simple y puede ser extendido fácilmente a otros factoriales de este tipo. Sin embargo, no siempre se obtiene el arreglo más práctico.

10.7. Implementación en SAS

A partir de los datos de los ejemplos 10.1 y 10.2 presentados a lo largo del capítulo, se presentan a continuación los programas en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos.

```
/* Diseño factorial 2^3 con confusión total */
/* Lectura de los datos del ejemplo 10.1 */

DATA EJEMPL0101;
INPUT REP BLOQUE A B C PUREZA @@;
CARDS;
1 1 0 0 1 44.5 1 1 0 1 0 44.2 1 1 1 0 0 60.1 1 1 1 1 1 48.8
1 2 0 0 0 46.8 1 2 0 1 1 44.5 1 2 1 0 1 57.0 1 2 1 1 0 58.5
2 3 1 0 1 49.8 2 3 1 1 0 52.0 2 3 0 1 1 48.8 2 3 0 0 0 51.5
2 4 0 0 1 55.5 2 4 1 0 0 59.8 2 4 0 1 0 56.0 2 4 1 1 1 58.5
3 5 0 1 1 53.2 3 5 1 0 1 57.2 3 5 0 0 0 56.0 3 5 1 1 0 59.0
3 6 1 0 0 69.5 3 6 0 1 0 62.8 3 6 0 0 1 55.0 3 6 1 1 1 53.8
;

/* Obtención del análisis de varianza con solo bloques */

PROC GLM DATA=EJEMPL0101;
CLASS BLOQUE A B C;
MODEL PUREZA=BLOQUE A B A*B C A*C B*C;

/* Obtención del análisis de varianza con réplicas y
bloques dentro de réplica */

PROC GLM DATA=EJEMPL0101;
CLASS REP BLOQUE A B C;
MODEL PUREZA=REP BLOQUE(REP) A B A*B C A*C B*C;

/* Obtención del análisis de varianza con réplicas,
efecto confundido y bloques dentro de réplica */

PROC GLM DATA=EJEMPL0101;
CLASS A B C REP BLOQUE;
MODEL PUREZA=A B A*B C A*C B*C REP A*B*C BLOQUE(REP)/SS1;

/* Diseño factorial 3^2 con confusión total */

/* Lectura de los datos del ejemplo 10.2 */

DATA EJEMPL0102;
INPUT TEMPERATURA SACAROSA BLOQUE T1S1 REPLICA ENERGIA @@;
CARDS;
```

```

20 20 1 1 1 3.1 20 40 3 2 1 5.5 20 60 2 3 1 7.9
20 20 1 1 2 3.7 20 40 3 2 2 6.7 20 60 2 3 2 9.2
20 20 1 1 3 4.7 20 40 3 2 3 7.3 20 60 2 3 3 9.3
30 20 2 2 1 6.0 30 40 1 3 1 11.5 30 60 3 1 1 17.5
30 20 2 2 2 6.9 30 40 1 3 2 12.9 30 60 3 1 2 15.8
30 20 2 2 3 7.5 30 40 1 3 3 13.4 30 60 3 1 3 14.7
40 20 3 3 1 7.7 40 40 2 1 1 15.7 40 60 1 2 1 19.1
40 20 3 3 2 8.3 40 40 2 1 2 14.3 40 60 1 2 2 18.0
40 20 3 3 3 9.5 40 40 2 1 3 15.9 40 60 1 2 3 19.9
;

/* Obtención del análisis de varianza con $T^1S^2$
confundido con el bloque */

PROC GLM DATA=EJEMPLO102;
CLASS TEMPERATURA SACAROSA BLOQUE T1S1;
MODEL ENERGIA=BLOQUE TEMPERATURA SACAROSA T1S1;

RUN;
```

10.8. Implementación en R

A partir de los datos de los ejemplos [10.1](#), [10.2](#) y [10.3](#), se presentan a continuación los programas en el software estadístico R.

```

#####
## Ejemplo 10.1 ##
#####

# Introducción de los datos del ejemplo 10.1

ejemplo10.1 <- data.frame(rep=factor(rep(c(1,1,2,2,3,3),4)),
  bloque=factor(rep(seq(1,6,by=1),4)),
  a=factor(c(0,0,1,0,0,1,0,0,1,1,1,0,1,1,0,0,0,0,1,1,0,1,1,1)),
  b=factor(c(0,0,0,0,1,0,1,1,1,0,0,1,0,0,1,1,0,0,1,1,0,1,1,1)),
  c=factor(c(1,0,1,1,1,0,0,1,0,0,1,0,0,1,1,0,0,1,1,0,0,1,0,1)),
  pureza=c(44.5,46.8,49.8,55.5,53.2,69.5,44.2,44.5,52.0,59.8,57.2,
  62.8,60.1,57.0,48.8,56.0,56.0,55.0,48.8,58.5,51.5,58.5,59.0,53.8))

## Obtención del análisis de varianza con solo bloques
anova10.1 <- aov(pureza ~ bloque+a+b+a*b+c+a*c+b*c,data=ejemplo10.1)
summary(anova10.1)

anova10.1.1 <- lm(pureza ~ bloque+a+b+a*b+c+a*c+b*c,data=ejemplo10.1)
summary(anova10.1.1)

## Obtención del análisis de varianza con réplicas y bloques
## dentro de réplica
```

```
anova10.1.2 <- aov(pureza ~ rep+bloque/rep+a+b+a*b+c+a*c+b*c,
data=ejemplo10.1)
summary(anova10.1.2)
```

```
anova10.1.3 <- aov(pureza ~ a+b+a*b+c+a*c+b*c+rep+a*b*c+Error(rep(bloque)),
data=ejemplo10.1)
summary(anova10.1.3)
```

```
#####
## Ejemplo 10.2 ##
#####
```

```
# Introducción de los datos del ejemplo 10.2
```

```
ejemplo10.2 <- data.frame(temperatura=factor(rep(c(20,20,20,30,30,30,40,40,
40),3)),
sacarosa=factor(c(rep(20,9),rep(40,9),rep(60,9))),
bloque=factor(c(1,1,1,2,2,2,3,3,3,3,3,3,1,1,1,2,2,2,2,2,3,3,3,1,1,1)),
T1S1=factor(c(1,1,1,2,2,2,3,3,3,2,2,2,3,3,3,1,1,1,3,3,3,1,1,1,2,2,2)),
replica=factor(c(rep(c(1,2,3),9))),
energia=c(3.1,3.7,4.7,6.0,6.9,7.5,7.7,8.3,9.5,5.5,6.7,7.3,11.5,12.9,
13.4,15.7,14.3,15.9,7.9,9.2,9.3,17.5,15.8,14.7,19.1,18.0,19.9))
```

```
anova10.2 <- aov(energia~bloque+temperatura+sacarosa+T1S1,data=ejemplo10.2)
summary(anova10.2)
```

```
#####
## Ejemplo 10.3 ##
#####
```

```
# Introducción de los datos del ejemplo 10.3
```

```
ejemplo10.3 <- data.frame(rep=factor(rep(c(1,1,2,2,3,3,4,4),4)),
bloque=factor(rep(seq(1,8,by=1),4)),
a=factor(c(0,0,1,0,1,1,1,0,1,1,0,1,0,0,1,0,1,0,1,0,0,1,0,1,0,1,0,1,0,1)),
b=factor(c(0,1,1,1,0,0,1,0,1,0,0,0,0,1,0,1,0,0,1,1,1,0,0,0,1,1,0,0,1,1,1)),
c=factor(c(0,0,0,1,0,1,1,0,1,1,0,1,1,0,0,1,0,1,1,0,0,0,1,1,1,0,1,0,1,1,0,0)),
rendimiento=c(7,24,36,31,28,31,66,11,39,31,19,36,24,19,31,29,30,21,41,30,35,
13,21,33,27,39,30,33,26,36,25,43))
```

```
anova10.3.1 <- aov(rendimiento ~ bloque+a*b*c,data=ejemplo10.3)
summary(anova10.3.1)
```

```
anova10.3.2 <- aov(rendimiento ~ rep+bloque/rep+a*b*c,data=ejemplo10.3)
summary(anova10.3.2)
```


10.9. Ejercicios

- En un experimento agrícola se ensayó el efecto de un fertilizante que contenía diferentes cantidades de N, P y K. Se manejaron las condiciones:

N	20	40	20	40	20	40	20	40
P	40	40	60	60	40	40	60	60
K	60	60	60	60	80	80	80	80

Suponga que el experimento se realizó en bloques tamaño 4, se desea estimar seis de los efectos de todas las posibles seis repeticiones.

- Genere un plan que satisfaga los requerimientos del problema indicando los tratamientos que deben ir en cada bloque.
- Proponga el modelo y escriba la tabla de ANOVA, señalando C de V, gl y E(CM)

- Suponga el siguiente arreglo del material experimental:

Réplica I	Réplica II	Réplica III
(1)=8 b=10	(1)=5 b=6	a=7 ab=10
a=7 ab=15	a=7 ab=16	(1)=6 b=12

- Indique el plan de confusión del arreglo anterior y proponga el modelo estadístico asociado.
 - Estime todos los parámetros involucrados en el modelo.
 - Presente la tabla de ANOVA y comente en detalle su conclusión.
- Se tiene un factorial 2^3 y se confunden las interacciones AB , AC , BC y ABC en las diferentes réplicas. Los datos que se presentan a continuación provienen de un ensayo de uniformidad.

Réplica I				Réplica II			
Bloque I		Bloque II		Bloque I		Bloque II	
(1)	25.7	a	23.2	(1)	27.6	a	25.6
ab	21.1	b	21.0	b	26.7	c	27.9
c	17.6	ac	18.6	ac	26.2	ab	28.5
abc	17.5	bc	18.3	abc	22.0	bc	27.2
$(AB)_0$		$(AB)_1$		$(AC)_0$		$(AC)_1$	

Réplica III				Réplica IV			
Bloque I		Bloque II		Bloque I		Bloque II	
(1)	21.4	b	18.8	(1)	23.9	a	25.4
bc	18.6	c	16.0	ab	21.4	b	26.9
a	18.8	ab	16.4	ac	20.6	c	25.2
abc	18.2	ac	16.6	bc	22.4	abc	30.1
$(BC)_0$		$(BC)_1$		$(ABC)_0$		$(ABC)_1$	

Lleve a cabo el análisis de varianza para estimar los efectos principales A , B y C al considerar estos tres factores como efectos fijos, aleatorios y mixtos.

4. Suponga un experimento factorial 2^3 . Se desea construir bloques tamaño 4, genere un plan de confusión de efectos principales, presente el análisis de varianza. Se suponen R réplicas del experimento básico.
5. Considere los datos del ejercicio 6 del capítulo 9. Con base en las dos réplicas obtenidas, construya dos bloques en los que se confunda la interacción entre los tres factores involucrados en cada réplica. Analice e interprete los resultados obtenidos.
6. Suponga que se condujo un experimento, el cual se desarrolló según el siguiente arreglo:

Bloque	Réplica I		Bloque	Réplica II	
1	011 (24)	000 (21)	1	100 (27)	001 (25)
	110 (28)	101 (25)		111 (26)	010 (25)
2	100 (28)	001 (20)	2	110 (23)	101 (22)
	111 (22)	010 (20)		000 (23)	011 (22)

Bloque	Réplica III	
1	010 (28)	100 (31)
	111 (25)	001 (24)
2	101 (25)	011 (24)
	110 (26)	000 (25)

- a. Indique el plan de confusión del arreglo anterior y proponga el modelo asociado.
- b. Estime todos los parámetros involucrados en el modelo.
- c. Lleve a cabo el ANOVA y escriba en detalle su conclusión.
- d. Escriba un programa en SAS que le permitirá analizar esta información.
- d. Escriba un programa en R que le permitirá analizar esta información.

7. Construya un plan de confusión para un 2^6 en bloques tamaño 8 en que no se confundan efectos principales ni interacciones de segundo orden.
8.
 - a. Verifique que es posible construir un plan para un diseño 2^8 en bloques de 64 unidades experimentales por bloque, sin confundir los efectos principales ni interacciones de segundo orden.
 - b. Construya el subgrupo intrabloque para el plan del punto a. usando la técnica que se deriva del *Teorema de Fisher*.
 - c. Escriba los generadores y las interacciones generalizadas confundidas con bloques para el plan del punto a.
 - d. Anote las repeticiones del experimento para el plan del punto a.
 - e. Calcule las varianzas tanto de las interacciones confundidas como de las no confundidas para el plan del punto a.
9. Un investigador está estudiando el efecto de diluentes de semen en la tasa de concepción en vacas lecheras. Usando un factorial completo con tres factores cada uno a dos niveles, los factores con sus respectivos niveles fueron:
 - A: Reducidor (Citrato, Fosfato)
 - B: Sulfanilamina (Sí, No)
 - C: Penicilina (No, Sí)

Cada colección provee semen únicamente para hacer cuatro de las posibles ocho diluciones. Como dos colecciones pueden hacerse para cada hembra, hay grandes posibilidades de encontrar diferencias sistemáticas entre las colecciones.

- a. ¿Qué arreglo experimental sugiere para evitar estas posibles diferencias sistemáticas?
- b. Suponga que se llevó a cabo el siguiente arreglo de tratamientos:

Tratamiento	Animal	
	1	2
(1)	78.3	74.9
ab	77.1	75.5
ac	76.9	73.0
bc	79.2	76.5
a	77.4	78.0
b	74.3	76.4
c	75.9	74.3
abc	78.5	78.2

En el experimento la respuesta de interés fue la tasa de concepción obtenida una vez aplicado el respectivo tratamiento. Con la información anterior, lleve a cabo el análisis y concluya:

- c. Decide llevar a cabo el experimento con el siguiente arreglo de los tratamientos: Animal 1 ((1) ac ab bc), (a b c abc). Animal 2 ((1) b ac abc), (a ab c bc). Se observa que hay dos réplicas para cada animal. Considerando las mismas tasas de respuesta del punto anterior, lleve a cabo el análisis de varianza y comente en detalle su conclusión.
10. Considere los datos del ejercicio 6 del capítulo 9. Con base en las dos réplicas obtenidas, construya dos bloques en que no se confunda los efectos principales en cada réplica y, además, no se confundan los mismos efectos en cada réplica. Analice e interprete los resultados obtenidos.
11. La siguiente información se refiere a la combinación de N, P y K aplicados a un cultivo en el rendimiento de arveja.

Réplica I				Réplica II			
Bloque 1		Bloque 2		Bloque 1		Bloque 2	
PK	(22.45)	P	(20.05)	PK	(22.14)	P	(24.00)
(1)	(21.25)	N	(28.12)	(1)	(23.36)	N	(25.40)
NP	(28.49)	NPK	(22.14)	NP	(23.54)	NPK	(26.54)
NK	(25.85)	K	(20.64)	NK	(22.59)	K	(25.19)

Réplica III			
Bloque 1		Bloque 2	
PK	(24.13)	P	(28.49)
(1)	(25.40)	N	(31.52)
NP	(26.76)	NPK	(25.31)
NK	(25.95)	K	(24.95)

- a. Indique el plan de confusión del arreglo anterior y proponga el modelo asociado.
- b. Estime todos los parámetros involucrados en el modelo.
- c. Presente la tabla de ANOVA y comente en detalle su conclusión.
- d. Para los efectos e interacciones significativas, dé una recomendación en términos del problema de interés.
- e. Analice la información usando SAS, Minitab, R y Statgraphics, compare los resultados y concluya.

12. Considere los datos del experimento presentado en el ejercicio 8 del capítulo 9. Suponga que no fue posible realizar las dos réplicas el mismo día y que tampoco fue posible realizar las nueve pruebas en la misma máquina, establezca un diseño para conducir el experimento en tres máquinas con una parte de la interacción confundida con los bloques en cada día. Analice e interprete los resultados obtenidos.
13. Suponga la siguiente información:

Bloque	Tratamiento		
1	(0,2)	(2,0)	(1,1)
	19	47	28
2	(1,0)	(0,1)	(2,2)
	84	3	35
3	(2,1)	(1,2)	(0,0)
	23	82	80
4	(2,2)	(0,0)	(1,1)
	34	72	41
5	(2,0)	(0,1)	(1,2)
	33	91	77
6	(2,1)	(0,2)	(1,0)
	46	13	59

Bloque	Tratamiento		
7	(1,1)	(0,2)	(2,0)
	65	99	20
8	(2,2)	(0,1)	(1,0)
	30	72	4
9	(0,0)	(2,1)	(1,2)
	17	3	37
10	(0,1)	(2,0)	(1,2)
	97	75	28
11	(1,0)	(2,1)	(0,2)
	32	9	12
12	(1,1)	(0,0)	(2,2)
	46	67	90

- Señale los efectos confundidos en cada caso y presente el modelo asociado.
 - Construya la tabla de ANOVA y comente en detalle sus conclusiones para el experimento.
14. Construya un diseño 3^4 en tres bloques utilizando el componente $A^1B^2C^2D^2$ de la interacción de cuatro factores en el plan de confusión.
15. Considere los datos del experimento presentado en el ejercicio 9 del capítulo 9. Suponga que no fue posible realizar las dos réplicas en la misma ciudad y tampoco fue posible realizar los 27 tratamientos el mismo día.
- Establezca un diseño para conducir el experimento en tres días con $A^1B^2C^1$ confundida con los bloques en cada ciudad. Analice e interprete los resultados obtenidos.
 - Si $A^1B^1C^1$ está confundida en la réplica I y $A^1B^1C^2$ está confundida en la réplica II, realice el análisis de varianza e interprete los resultados.

Capítulo *once* **Diseños factoriales fraccionados y parcelas divididas**

En este capítulo, se presentan los diseños factoriales fraccionados y el diseño de parcelas divididas para experimentos factoriales y se describen algunas características relativas a la estructura de los mismos: la composición de los errores, el análisis estadístico y la eficiencia relativa en el diseño de parcelas divididas.

11.1. Diseños factoriales fraccionados

El principio de confusión dio origen a los *factoriales fraccionados*. Estos arreglos fueron propuestos por Finney (1945) y llevan en consideración el uso de algunos bloques de una réplica dentro de algún patrón de confusión. Estos diseños son ampliamente usados en la industria, biología, agronomía, biotecnología, mercadeo, entre otras áreas del conocimiento científico. Estos arreglos se recomiendan en los siguientes casos:

1. Cuando se consideren *a priori* algunas interacciones de orden superior como negligibles.
2. En situaciones preliminares de filtrado de factores. Esto es recomendable cuando se tienen muchos factores que influyen en el proceso. Sin embargo, se espera que solo unos cuantos sean importantes. Los factoriales fraccionados de más interés son los que permiten seleccionar los factores más importantes.
3. En experimentos secuenciales. Puesto que en estos se van agregando tratamientos dependiendo de los resultados de los ensayos anteriores.

Es frecuente que en las primeras etapas de una investigación se tenga interés en estudiar muchos factores, por ejemplo, 9 o más. Para experimentar con esta cantidad de factores, se requiere una estrategia que permita reducir de manera importante el número de puntos experimentales, pero que al mismo tiempo pierda el mínimo de información valiosa para la investigación. Tal estrategia la conforman los *diseños factoriales fraccionados*, los cuales, gracias al exceso de información que acumulan los *diseños factoriales completos* cuando se estudian muchos factores, permiten sacrificar información poco importante en aras de un diseño manejable en cuanto al número de puntos experimentales y en el análisis e interpretación del ensayo experimental. Es decir, los diseños factoriales fraccionados, como su nombre lo indica, son una parte o una fracción de los diseños factoriales completos, permiten reducir el número de corridas experimentales y, al mismo tiempo, obtener la información acerca de los efectos considerados de antemano relevantes.

La teoría de diseños factoriales fraccionados se basa en una jerarquización de los efectos: los más importantes son los efectos principales, seguidos por las interacciones dobles, luego las triples, cuádruples y, finalmente, las de orden superior.

Por ejemplo, una réplica completa de un diseño 2^6 requiere de 64 tratamientos. En este diseño, solo 6 de los 63 grados de libertad corresponden a los efectos principales, 15 a las interacciones de dos factores y los 42 grados de libertad restantes se asocian con las interacciones de tres o más factores. Si el investigador puede suponer en forma razonable que ciertas interacciones de orden superior son insignificantes (supuesto apoyado por la teoría de series de Taylor), es posible obtener información de los efectos principales y las interacciones de orden inferior corriendo únicamente una fracción del experimento factorial completo.

Cabe aclarar que cuando se corre solo una fracción del diseño factorial completo, se debe tener en cuenta que:

1. Se pierde información, ya que habrá efectos que no podrán estimarse, y se tienen menos grados de libertad disponibles para el error.
2. Los efectos que sí se pueden estimar tienen al menos un *alias*. El que un *efecto* sea *alias* de otro significa que son en realidad el mismo efecto con nombres distintos, y al estimar a uno de ellos se estima al mismo tiempo el otro, de manera que no se pueden separar en el análisis. Cuando el experimentador elige una fracción en la que los dos efectos potencialmente importantes son alias, debe contar de antemano con una estrategia de interpretación del efecto estimado.

Estas dos consecuencias se entenderán mejor en el contexto de las fracciones que se construirán como ejemplos en este capítulo; primero se presentará el fraccionado un medio de un diseño factorial 2^k , luego se pasará al fraccionamiento de cualquier grado superior.

11.1.1. Fracción un medio del diseño 2^k

Se considera inicialmente el caso en el que se estudian tres factores, cada uno con dos niveles, debido a que los experimentadores no pueden costear (en términos de tiempo y/o dinero) las combinaciones de los $2^3 = 8$ tratamientos pero sí pueden costear cuatro tratamientos, se sugiere una fracción del diseño completo, por ejemplo, un medio de un diseño 2^3 . La fracción un medio de un diseño 2^3 se conoce como un diseño $2^{3-1} = \frac{1}{2}2^3$.

En la tabla 11.1, se muestra la agrupación de signos positivos y negativos del diseño 2^3 . Suponga que se seleccionan las cuatro combinaciones de tratamientos a, b, c y abc como la fracción un medio con la que se trabajará. Estos tratamientos se muestran en la parte superior de dicha tabla.

Tabla 11.1: Signos positivos y negativos del diseño factorial 2^3

Combinación de tratamientos	Efecto factorial							
	I	A	B	AB	C	AC	BC	ABC
a	+	+	-	-	-	-	+	+
b	+	-	+	-	-	+	-	+
c	+	-	-	+	+	-	-	+
abc	+	+	+	+	+	+	+	+
ab	+	+	+	+	-	-	-	-
ac	+	+	-	-	+	+	-	-
bc	+	-	+	-	+	-	+	-
(1)	+	-	-	+	-	+	+	-

El diseño 2^{3-1} se forma al seleccionar solo las cuatro combinaciones de tratamientos que producen un signo positivo sobre la columna ABC . Por esto, ABC se denomina *generador* de esta fracción. Además, la columna identidad I siempre es positiva, por lo cual, $I = ABC$, y se denominará la *relación de definición* del diseño.

Las combinaciones de tratamientos del diseño 2^{3-1} producen tres grados de libertad que pueden usarse para estimar los efectos principales. Las observaciones que se utilizan para estimar los efectos principales A, B y C son las siguientes:

$$l_A = \frac{1}{2}(a - b - c + abc)$$

$$l_B = \frac{1}{2}(-a + b - c + abc)$$

$$l_C = \frac{1}{2}(-a - b + c + abc).$$

También es fácil verificar que las combinaciones lineales que se usan para estimar las interacciones de dos factores son:

$$l_{AB} = \frac{1}{2}(-a - b + c + abc)$$

$$l_{AC} = \frac{1}{2}(-a + b - c + abc)$$

$$l_{BC} = \frac{1}{2}(a - b - c + abc).$$

Se observa de estas combinaciones que: $l_A = l_{BC}$, $l_B = l_{AC}$ y $l_C = l_{AB}$; en consecuencia, es imposible distinguir entre A y BC , B y AC y, C y AB . De

hecho, es posible mostrar que cuando se estiman A , B , y C en realidad lo que se está haciendo es estimar $A + BC$, $B + AC$ y $C + AB$. Cuando esto sucede, se dice que A y BC son *alias*, B y AC son *alias* y, C y AB son *alias*.

La *estructura de alias* de un diseño factorial fraccionado se puede obtener de la relación de definición del diseño. Cuando se multiplica cada efecto por esta relación, con el uso de *multiplicación módulo 2*, se obtiene directamente la estructura de alias. Este concepto significa que al multiplicar en aritmética módulo 2 cualquier efecto por la identidad es igual al efecto y al multiplicar un efecto por sí mismo es igual a la identidad (relación de definición). Por ejemplo, realizando este procedimiento al efecto A , se tendría que $AI = A$ y $(AA)_{\text{mód } 2} = A^2 = A^0 = I$. Entonces, el alias de A se obtiene al multiplicar por A los dos lados de la relación $I = ABC$, obteniendo $AI = A(ABC) = A^2BC = BC$ y, también, los alias de B y C respectivamente, $BI = B(ABC) = AB^2C = AC$ y $CI = C(ABC) = ABC^2 = AB$.

A esta fracción un medio, con $I = ABC$, suele llamársele la *fracción principal* del diseño.

Observación 11.1. Cuando se fracciona un diseño más grande resulta más práctico obtener la estructura de alias a partir de la relación de definición del diseño que de los contrastes.

Si ahora se elige la otra mitad de la réplica, esta se compone de las combinaciones de tratamientos de la tabla 11.1 que tienen el signo negativo asociado con ABC , la relación de definición de este diseño es $I = -ABC$.

Usando la fracción alterna las combinaciones lineales de las observaciones son:

$$\begin{aligned} l_A^* &= \rightarrow A - BC \\ l_B^* &= \rightarrow B - AC \\ l_C^* &= \rightarrow C - AB. \end{aligned}$$

En la práctica, no importa cuál de las dos fracciones se utilice, puesto que se forma el diseño 2^3 completo al combinar las dos fracciones y se cuenta con los ocho ensayos asociados con el diseño completo. En este caso, pueden obtenerse las estimaciones de todos los efectos, sin los alias, analizando los ocho ensayos en un diseño completo con dos bloques de cuatro ensayos cada uno. Esto también se logra sumando y restando la combinación lineal a los efectos de las dos fracciones individuales; por ejemplo, al considerar $l_A \rightarrow A + BC$ y $l_A^* \rightarrow A - BC$, esto implica que:

$$\frac{1}{2}(l_A + l_A^*) = \frac{1}{2}(A + BC + A - BC) = A$$

$$\frac{1}{2}(l_A - l_A^*) = \frac{1}{2}(A + BC - A + BC) = BC.$$

Por lo tanto, usando los tres pares de combinaciones lineales se obtiene:

i	$\frac{1}{2}(l_i + l_i^*)$	$\frac{1}{2}(l_i - l_i^*)$
A	A	BC
B	B	AC
C	C	AB

11.1.2. Resolución de un diseño

Al correr un diseño factorial fraccionado, los efectos no pueden estimarse de manera aislada, sino que se estiman las sumas (o restas) de efectos de alias como se observa en el arreglo anterior. La interpretación de los alias que se suman se hace fácilmente al suponer que todos los sumandos excepto uno no son importantes. Así, el efecto total se puede atribuir a este único efecto que se considera relevante. La estrategia entonces es elegir, siempre que sea posible, diseños fraccionados en los cuales los efectos potencialmente importantes sean alias de efectos de antemano irrelevantes.

Bajo el supuesto de que los efectos principales son más importantes que las interacciones de dos factores, y éstas a su vez son más relevantes que las de tres, y así sucesivamente, se recomienda utilizar diseños factoriales fraccionados que tengan alta *resolución*.

Definición 11.1. Un diseño factorial fraccionado es de resolución R si los efectos formados por la interacción de p factores no son alias de efectos de interacción que tengan menos de $R - p$ factores.

A mayor resolución se observa más claramente lo que sucede con los efectos potencialmente importantes (principales e interacciones). Para fines prácticos basta entender los diseños particulares de resolución III, IV y V que se presentan continuamente.

1. **Diseños resolución III.** Permiten estudiar los efectos principales bajo el supuesto de que todas o algunas interacciones son negligibles. En estos diseños ningún efecto principal es alias de otro efecto principal, pero los efectos principales son alias de interacciones de dos o más factores y las interacciones dobles son alias de otras semejantes o mayores.

En la relación de definición I , siempre deben aparecer interacciones de tres o más factores; los arreglos más usuales son:

- a. 2^{3-1} , con relación de definición $I = ABC$.
 - b. 2^{5-2} , con relación de definición $I = ABD = ACE$ y la interacción generalizada $I = BCDE$.
 - c. 2^{7-4} , con relación de definición $I = ABD = ACE = BCF = ABCG$ y las correspondientes interacciones generalizadas $BCDE = ACDF = CDG = ABEF = BEG = AFG = DEF = ADEG = CEF = BDFG = ABCDEFG$.
2. **Diseños resolución IV.** En estos diseños, ningún efecto principal tiene como alias otros efectos principales o interacciones de dos factores. Las interacciones de dos factores forman alias entre sí o con interacciones de orden superior. En este caso, la relación de definición debe tener interacciones de cuatro o más factores. Como ejemplo se tiene el diseño 2^{6-2} , con relación de definición $I = ABCE = BCDF$ y con la interacción generalizada $I = ADEF$.
3. **Diseños resolución V.** En estos diseños, ningún efecto principal o interacción de dos factores tiene como alias otro efecto principal o interacciones de dos factores, pero las interacciones de dos son alias de las interacciones de tres factores. En la relación de definición hay cinco o más factores.

En general, en los diseños factoriales fraccionados con dos niveles la resolución está dada por la relación de definición con el menor número de letras. Por ejemplo, en los diseños 2^{k-1} la resolución es igual al número de letras del generador, es decir, k , ya que este es al mismo tiempo la relación de definición. Así, las fracciones 2^{3-1} , 2^{4-1} y 2^{5-1} tienen resolución III, IV y V, respectivamente, porque sus correspondientes generadores se componen de 3, 4 y 5 letras.

Ejemplo 11.1. *En una planta donde se fabrican semiconductores, se quiere mejorar el rendimiento del proceso. De acuerdo con la experiencia del grupo de la planta, los factores que podrían tener mayor influencia sobre el rendimiento son: A, el nivel de la abertura (pequeña y grande); B, tiempo de exposición (20 % abajo y 20 % arriba); C, tiempo de revelado (30 seg y 45 seg); y D, dimensión de la máscara (pequeña y grande). Se decidió realizar media fracción con una sola réplica para estudiar estos cuatro factores. De acuerdo con la experiencia del grupo, la interacción entre los cuatro factores no es relevante. Al tomar la fracción principal, la relación de definición es $I = ABCD$.*

El grupo de investigadores realizó las aleatorizaciones apropiadas, en cuanto a la asignación de los tratamientos a cada una de las unidades experimentales, y midió los rendimientos, encontrando los resultados que se presentan en la tabla 11.2.

Tabla 11.2: Rendimientos en la planta al realizar un factorial fraccionado 2^{4-1} con la relación de definición $I = ABCD$

Diseño básico				Combinación de tratamientos	Rendimiento
<i>A</i>	<i>B</i>	<i>C</i>	$D = ABC$		
-	-	-	-	(1)	7
+	-	-	+	<i>ad</i>	10
-	+	-	+	<i>bd</i>	32
+	+	-	-	<i>ab</i>	55
-	-	+	+	<i>cd</i>	18
+	-	+	-	<i>ac</i>	20
-	+	+	-	<i>bc</i>	40
+	+	+	+	<i>abcd</i>	61

Este diseño básico tiene ocho tratamientos, pero solo tres factores en el plan, los cuales generan los niveles del cuarto factor. Para encontrar los signos de este factor, se resuelve la relación de definición $I = ABCD$ para D , encontrando que $DI = ABC$. Por lo tanto, el nivel de D en cada tratamiento es el producto de los signos de las columnas A , B y C . El proceso se ilustra en la tabla 11.2.

Para ilustrar los cálculos, las combinaciones lineales de las observaciones asociadas con los efectos A y AB , respectivamente, son:

$$\begin{aligned}
 l_A &= \frac{1}{4}(A_1 - A_0) = \frac{1}{4}(ad + ab + ac + abcd - (1) - bd - cd - bc) \\
 &= \frac{1}{4}(10 + 55 + 20 + 61 - 7 - 32 - 18 - 40) = 12.25 \rightarrow A + BCD \\
 l_{AB} &= \frac{1}{4}[(AB)_0 - (AB)_1] = \frac{1}{4}((1) + ab + cd + abcd - ad - bd - ac - bc) \\
 &= \frac{1}{4}(7 + 55 + 18 + 61 - 10 - 32 - 20 - 40) = 9.75 \rightarrow AB + CD.
 \end{aligned}$$

En la tabla 11.3, se presentan las diferentes estimaciones de los parámetros asociados con los efectos, así como la estructura de alias. Se nota que el diseño factorial fraccionado empleado en este ejemplo es de resolución III.

Como se cuenta con una sola réplica por unidad de tratamiento, se deben llevar algunos efectos de poca importancia al error para tener grados de libertad y poder, así, realizar el análisis de varianza. No es conveniente concluir a partir de los resultados presentados en la tabla 11.3 que los efectos principales A , B y C son “grandes” (mayores valores en la estimación). Además, si A , B y C son los efectos principales importantes, es lógico concluir que la interacción $AB + CD$ tiene efecto grande, puesto que la interacción AB también es significativa. Estos resultados se confirman

al realizar el análisis de varianza correspondiente, el cual se presenta en la tabla 11.4. A partir de los resultados presentados en esta tabla, se encuentra que el nivel de la abertura, el tiempo de exposición, el tiempo de revelado y la interacción entre el nivel de abertura y el tiempo de exposición son significativos. La inclusión de estas variables explica más del 99 % de la variabilidad total del rendimiento.

Tabla 11.3: Estimación de los efectos y los alias para los datos sobre el rendimiento

Estimación			Estructura de alias		
l_A	=	12.25	l_A	→	$A + BCD$
l_B	=	33.25	l_B	→	$B + ACD$
l_{AB}	=	9.75	l_{AB}	→	$AB + CD$
l_C	=	8.75	l_C	→	$C + ABD$
l_D	=	-0.25	l_D	→	$D + ABC$
l_{AC}	=	-0.75	l_{AC}	→	$AC + BD$
l_{AD}	=	-1.75	l_{AD}	→	$AD + BC$

Tabla 11.4: Análisis de varianza para el rendimiento de un proceso

C de V	gl	SC	CM	F	Valor p
Modelo	4	2854.52	713.63	290.29	0.000
A	1	300.13	300.13	122.08	0.002
B	1	2211.13	2211.13	899.44	0.000
$A * B$	1	190.13	190.13	77.34	0.003
C	1	153.13	153.15	62.29	0.004
Error	3	7.38	2.46		
Total	7	2861.90			

Al suponer ahora que el experimentador decide recurrir a la fracción complementaria, la relación de definición sería $I = -ABCD$. Usando la fracción alterna, las combinaciones lineales de las observaciones se presentan en la tabla 11.5.

Las combinaciones lineales de las observaciones que se obtienen con esta fracción complementaria son:

$$\begin{aligned} l_A^* &= A - BCD = 10.00 \\ l_B^* &= B - ACD = 34.00 \\ l_{AB}^* &= AB - CD = 6.00 \\ l_C^* &= C - ABD = 10.50 \\ l_{AC}^* &= AC - BD = 0.50 \\ l_{BC}^* &= BC - AD = 0.50 \\ l_D^* &= D - ABC = 0.50. \end{aligned}$$

Tabla 11.5: Rendimiento del proceso al realizar un diseño factorial fraccionado con la relación de definición $I = -ABCD$

Diseño básico			Combinación de		
A	B	C	$D = -ABC$	tratamiento	Rendimiento
-	-	-	+	d	6
+	-	-	-	a	9
-	+	-	-	b	34
+	+	-	+	abd	50
-	-	+	-	c	16
+	-	+	+	acd	21
-	+	+	+	bcd	44
+	+	+	-	abc	60

Estas estimaciones pueden combinarse con las que se obtuvieron de la fracción un medio original (tabla 11.3), obteniendo las siguientes estimaciones de efectos:

i	$\frac{1}{2}(l_i + l_i^*)$		$\frac{1}{2}(l_i - l_i^*)$	
A	11.125	$\rightarrow$	A	1.125 $\rightarrow$ BCD
B	33.625	$\rightarrow$	B	-0.375 $\rightarrow$ ACD
AB	7.875	$\rightarrow$	AB	1.875 $\rightarrow$ CD
C	9.625	$\rightarrow$	C	-0.875 $\rightarrow$ ABD
AC	-0.125	$\rightarrow$	AC	-0.625 $\rightarrow$ BD
AD	-0.625	$\rightarrow$	AD	-1.125 $\rightarrow$ BC
D	0.125	$\rightarrow$	D	-0.375 $\rightarrow$ ABC

Estas estimaciones serían las mismas que se habrían obtenido si se hubiese corrido el factorial completo con una sola réplica. Se observa que los resultados del factorial completo son similares a los del factorial fraccionado inicial, ya que las interacciones dobles y triples, excepto la interacción AB , no son relevantes en el experimento. En este caso, los efectos principales A , B y C son relevantes.

11.1.3. Fracción un cuarto del diseño 2^k

A partir de la discusión anterior resulta claro que la relación de definición para la fracción un medio incluye interacciones de orden superior; sin embargo, esta puede tener aún muchos tratamientos. Por ello, fracciones de grado superior tales como $\frac{1}{4}$, $\frac{1}{8}$, $\dots$, pueden ser más viables en estos casos. Para ilustrar este proceso, se considera un cuarto del factorial 2^7 con los factores caracterizados por A , B , C , D , E , F y G , obteniendo (1, 2, 3, 4, 5, 7).

Para la construcción de este factorial se procede de la siguiente manera:

1. Divida el conjunto de las 2^7 tratamientos dentro de dos conjuntos basados en el signo (matemática módulo 2) con el cual estos entran, según la interacción seleccionada, por ejemplo: $ABDC$ ($I = ABCD$).

2. Escoja una de las dos fracciones.
3. Divida de nuevo el conjunto escogido en dos subconjuntos, basados, otra vez, en el signo con el cual los tratamientos se asignan según otra interacción seleccionada, por ejemplo, $BEFG$ ($I = BEFG$).

Las interacciones seleccionadas de la anterior forma son ortogonales y el resultado final es un conjunto de $2^5 = 32$ tratamientos. Esta forma de construcción puede ser empleada para cualquier otro diseño factorial fraccionado. La estructura empleada en este caso es muy similar a la empleada en el caso de la construcción de los bloques en un diseño factorial con confusión.

Para la construcción se pueden seleccionar los 32 tratamientos en los que los signos en las interacciones $ABDC$ y $BEFG$ sean los mismos. Por consiguiente, $ABDC$ y $BEFG$ están confundidas con la media, la interacción generalizada $(ABDC)(BEFG) = ACDEFG$ también está confundida con la media, es decir, los 32 tratamientos tienen el mismo signo de la interacción $ACDEFG$. Con esto, se sigue entonces que la relación de definición es $I = ABDC = BEFG = ACDEFG$.

Esta relación indica que efectos principales están confundidos con interacciones de tres o más factores, interacciones de dos factores también están confundidas con interacciones de dos o más factores, por ejemplo, $A = BDC = ABEFG = CDEFG$ y $AD = BC = ABDEFG = CEFG$.

La relación de definición anterior determina la fracción un cuarto. Este diseño es un factorial fraccionado de resolución IV y se denota como 2^{7-2}_{IV} . La estructura de alias completa del diseño se obtiene multiplicando cada efecto por la relación de definición ($I = ABCD = BEFG = ACDEFG$).

11.1.4. Diseño factorial fraccionado 2^{k-p}

En general, un *diseño factorial fraccionado* 2^{k-p} es una fracción $\frac{1}{2^p}$ del diseño factorial completo 2^k . Para construir un diseño 2^{k-p} , se eligen p (interacciones de orden superior) generadores iniciales, en lo posible deben ser interacciones del más alto orden, de manera que todos los productos también sean interacciones de alto orden; una vez elegidos los p generadores, el diseño se puede construir en los siguientes dos pasos:

- a. Se presenta el diseño 2^{k-p} como si fuese un factorial completo para $k - p$ factores.
- b. Para los últimos p factores, las columnas de signos se obtienen multiplicando las columnas que indican los generadores.

La *relación de definición* tiene tantos términos como productos se puedan hacer con los p generadores. Así, cada efecto tiene

$$\binom{p}{1} + \binom{p}{2} + \cdots + \binom{p}{p}$$

alias. De la relación de definición del diseño, se obtiene la estructura de alias y la resolución de la fracción resultante.

En todo el procedimiento descrito, quizá lo más difícil es encontrar los mejores generadores de la fracción que se desea construir; afortunadamente, existen tablas de diseños factoriales fraccionados que incluyen la estructura de alias (McLean y Anderson 1984, Hinkelman y Kempthorne 1994, Hinkelman y Kempthorne 2005, Hinkelman y Kempthorne 2007), lo que permite al investigador elegir el diseño y saber, con anticipación, cuáles serían los alias de los efectos potencialmente importantes. Otra alternativa es utilizar un *software* estadístico para generar la fracción deseada y su estructura de alias, véase Acosta (1999) para un desarrollo en SAS.

La estimación de los efectos y las sumas de cuadrados en los diseños factoriales fraccionados 2^{k-p} se obtienen a partir de los contrastes, de manera similar a como se hace con los factoriales completos 2^k . Se obtiene un contraste para cada grupo de efectos y se pondera por una constante apropiada para estimar el efecto correspondiente, como en el caso de la diferencia de medias. Así, el efecto de un grupo de efectos X se estima como:

$$\widehat{X} = efecto = \frac{contraste}{2^{k-p-1}}$$

y su correspondiente suma de cuadrados es

$$SC(efecto) = \frac{(contraste)^2}{2^{k-p-1}} = 2^{k-p-1} [efecto]^2,$$

con un grado de libertad y la varianza de cada efecto

$$Var(efecto) = \frac{1}{2^{k-p-1}} \sigma^2.$$

Ejemplo 11.2. *Box y Hunter (1961) y Méndez (1993) presentan un experimento, en el cual se usó un diseño de resolución III para una unidad de manufactura en el proceso de filtrado. Comparado con otras unidades, se producía un mal producto y con mucho tiempo de filtrado. Para bajar este tiempo un comité decidió estudiar los siguientes factores: A, Agua de tubo y de pozo; B, materia prima producida en la planta y en otra planta; C, temperatura de filtrado (baja y alta); D, tiempo de*

reposo (bajo y alto); E, con y sin reciclaje; F, proporción de adición de Soda Caústica (NaOH, rápido y lento) y G, filtros (nuevos y viejos).

El factorial completo tendría $2^7 = 128$ tratamientos. Se usó un factorial $2^{7-4}_{III} = \frac{1}{16}2^7$. La siguiente relación de definición:

$$I = ABE = ACF = BCG = ABCD.$$

En la construcción de la fracción, se partió de un factorial completo 2^3 que se presenta a continuación:

A	B	C	D = ABC	E = AB	F = AC	G = BC	Tratamiento	Tiem. filt.
-	-	-	-	+	+	+	0000111	68.4
+	-	-	+	-	-	+	1001001	77.7
-	+	-	+	-	+	-	0101010	66.4
+	+	-	-	+	-	-	1100100	81.0
-	-	+	+	+	-	-	0011100	78.6
+	-	+	-	-	+	-	1010010	41.2
-	+	+	-	-	-	+	0110001	68.7
+	+	+	+	+	+	+	1111111	38.7

La anterior tabla se construyó a partir de la fracción en la que se confundieron los siguientes efectos:

$$(ABE)_1 \quad (ACF)_1 \quad (BCG)_1 \quad (ABCD)_0.$$

El conjunto total de generadores se obtiene a partir del producto de las interacciones 2 a 2, 3 a 3 y de las cuatro, presentadas en la relación de definición. Estas son:

$$ABE \times ACF = BCEF, \dots, BCG \times ABCD = ADG$$

$$ABE \times ACF \times BCG = EFG, \dots, ACF \times BCG \times ABCD = CDFG$$

$$ABE \times ACF \times BCG \times ABCD = ABCDEFG.$$

El grupo de alias en este caso solamente tiene en cuenta los asociados a los efectos principales:

$$A \times I = BE = CF = ABCG = BCD = \dots = BCDEFG$$

$$B \times I = AE = ABCF = CG = ACD = \dots = ACDEFG$$

$$C \times I = ABCE = AF = BG = ABD = \dots = ABDEFG$$

$$D \times I = ABDE = ACDF = BCDG = ABC = \dots = ABCEFG$$

$$E \times I = AB = ACEF = BCEG = ABCDE = \dots = ABCDFG$$

$$F \times I = ABEF = AC = BCFG = ABCDF = \dots = ABCDEG$$

$$G \times I = ABEG = ACFG = BC = ABCDG = \dots = ABCDEF.$$

Al despreciar las interacciones de tercer orden o más, se tienen como estimadores las siguientes combinaciones:

$$\begin{aligned}
 l_1 &= A + BE + CF + DG \\
 &= \frac{1}{4}[77.7 + 81 + 41.2 + 38.7 - 68.4 - 66.4 - 78.6 - 68.7] \\
 &= -10.875 \\
 l_2 &= B + AE + CG + DF = -2.8 \\
 l_3 &= C + AF + BG + DE = -16.6 \\
 l_4 &= D + CE + BF + AG = 0.5 \\
 l_5 &= E + AB + CD + FG = 3.2 \\
 l_6 &= F + AC + BD + EG = -22.8 \\
 l_7 &= G + BC + AD + EF = -3.425.
 \end{aligned}$$

Los estimadores $-10, 9, -16, 6$ y $-22, 8$ son considerados grandes, de ahí que se puede afirmar que los efectos del agua, temperatura y adición de NaOH son importantes en la reducción del tiempo de filtrado. Puede suceder que haya efectos de C, F y la interacción CF, que es alias de A, o bien que los efectos reales sean A, C y AC, que es alias de F.

Con el fin de ver mejor los efectos, se agregó una segunda fracción del experimento 2^{7-4}_{III} , según el siguiente arreglo:

A	B	C	D	E	F	G	Tratamiento	Tiempo filt.
+	+	+	+	-	-	-	1111000	66.7
-	+	+	-	+	+	-	0110110	65.0
+	-	+	-	+	-	+	1010101	86.4
-	-	+	+	-	+	+	0011011	61.9
+	+	-	-	-	+	+	1100011	47.8
-	+	-	+	+	-	+	0101101	59.0
+	-	-	+	+	+	-	1001110	42.6
-	-	-	-	-	-	-	0000000	67.6

Los estimadores para este segundo diseño son:

$$\begin{aligned}
 l_1^* &= -A + BE + CF + DG = 2.5 \\
 l_2^* &= -B + AE + CG + DF = 5.0 \\
 l_3^* &= -C + AF + BG + DE = -15.8 \\
 l_4^* &= -D + CE + BF + AG = 9.2 \\
 l_5^* &= -E + AB + CD + FG = 2.3
 \end{aligned}$$

$$l_6^* = -F + AC + BD + EG = -15.6$$

$$l_7^* = -G + BC + AD + EF = 3.3.$$

Al combinar las dos componentes del diseño, se obtienen los estimadores para el diseño agregado:

	$\frac{1}{2}(l_i - l_i^*)$		$\frac{1}{2}(l_i + l_i^*)$
$A =$	-6.7	$BE + CF + DG =$	-4.2
$B =$	-3.9	$AE + CG + DF =$	1.1
$C =$	-0.4	$AF + BG + DE =$	-16.2
$D =$	-4.4	$CE + BF + AG =$	4.9
$E =$	2.8	$AB + CD + FG =$	0.5
$F =$	-19.2	$AC + BD + EG =$	-3.6
$G =$	-0.1	$BC + AD + EF =$	-3.4

Los efectos más importantes fueron F y AF y, con menor importancia, A . Enviando los demás efectos e interacciones al error, se obtiene el análisis de varianza que se presenta en la tabla 11.6. En dicha tabla, se corroboran estos resultados (son significativos) y, además, se obtiene el efecto de bloque debido a que esta fracción fue obtenida en dos instantes diferentes (dos fracciones del ensayo). Este efecto no es significativo, aunque, como se mencionó en los capítulos anteriores, este no es el interés en esta clase de experimentos, ya que el interés es ver el efecto de los factores e interacciones.

Tabla 11.6: Análisis de varianza para los datos del tiempo de filtrado

C. de V	gl	SC	CM	F	Valor p
Modelo	4	2735.38	683.84	17.41	0.000
A	1	178.89	178.89	4.56	0.056
F	1	1476.48	1476.48	37.60	0.000
$A * F$	1	1044.90	1044.90	26.61	0.000
Bloque	1	35.10	35.10	0.89	0.365
Error	11	431.95	39.27		
Total	15	3167.33			

11.1.5. Réplicas fraccionadas del diseño factorial 3^k

El concepto de réplica fraccionada puede extenderse a los diseños 3^k . Debido a que una réplica completa del diseño 3^k puede requerir un número bastante grande de tratamientos, incluso para valores moderados de k , las réplicas fraccionadas de estos diseños son de interés. Sin embargo, algunos de estos diseños tienen estructura de alias complicadas.

En este caso, al igual que en los diseños factoriales fraccionados 2^{k-p} , las interacciones de orden superior se consideran poco importantes. Por este motivo, se puede considerar solamente una fracción de todos los posibles tratamientos. En este método, se considera una fracción $1/3^p$ del factorial completo 3^k ($p < k$), en que la fracción contiene 3^{k-p} tratamientos. A este diseño se le llama *diseño factorial fraccionado* 3^{k-p} .

La fracción más grande del diseño 3^k es la fracción un tercio que contiene 3^{k-1} tratamientos. Por consiguiente, se hace referencia a este como el diseño factorial fraccionado 3^{k-1} . Para construir un diseño factorial fraccionado 3^{k-1} , se selecciona un componente de interacción con dos grados de libertad, generalmente la interacción de orden más alto, y se hace la partición del diseño completo 3^k en tres bloques. Cada uno de estos es un diseño fraccionado 3^{k-1} (puede seleccionarse cualquiera de los bloques como fracción de trabajo para implementarlo). Si $A^{\alpha_1}B^{\alpha_2}C^{\alpha_3} \dots K^{\alpha_k}$ es el componente de la interacción utilizado para definir los elementos dentro los bloques, entonces a $I = A^{\alpha_1}B^{\alpha_2}C^{\alpha_3} \dots K^{\alpha_k}$ se le llama la *relación de definición* del diseño factorial fraccionado. Cada efecto principal o componente de interacción estimado a partir del diseño 3^{k-1} tiene dos alias, los cuales pueden encontrarse multiplicando el efecto tanto por I como por I^2 módulo 3.

Para ilustrar el procedimiento, se considera una fracción un tercio del factorial 3^3 , es decir, 9 de los posibles 27 tratamientos. Puede seleccionarse cualquiera de los componentes de la interacción ABC , esto es, $A^1B^1C^1$, $A^1B^1C^2$, $A^1B^2C^1$ y $A^1B^2C^2$ para construir el diseño, estas componentes son:

$$\alpha_1x_1 + \alpha_2x_2 + \alpha_3x_3 = 0, 1, 2 \text{ mód } 3,$$

donde $\alpha_1, \alpha_2, \alpha_3 = 1, 2, 3$. Suponga que se selecciona el componente de $A^1B^1C^2$, entonces cada fracción del diseño 3^{k-1} resultante contendrá exactamente $3^2 = 9$ tratamientos que deben satisfacer $x_1 + x_2 + 2x_3 = 0, 1, 2$ mód 3.

Con cualquiera de las anteriores fracciones 3^{k-1} , la estructura de alias resultante es:

$$\begin{aligned} A &= A(A^1B^1C^2) = A^2B^1C^2 = A^1B^2C^1 \\ A &= A(A^1B^1C^2)^2 = A^3B^2C^1 = B^2C^1 = B^1C^2 \\ B &= B(A^1B^1C^2) = A^1B^2C^2 \\ B &= B(A^1B^1C^2)^2 = A^2B^3C^1 = A^1C^2 \\ C &= C(A^1B^1C^2) = A^1B^1C^3 = A^1B^1 \\ C &= C(A^1B^1C^2)^2 = A^2B^2C^5 = A^1B^1C^1 \end{aligned}$$

$$A^1B^2 = A^1B^2(A^1B^1C^2) = A^2B^3C^2 = A^1C^1$$

$$A^1B^2 = A^1B^2(A^1B^1C^2)^2 = A^3B^4C^4 = B^1C^1.$$

Se puede elegir entre una de las siguientes tres fracciones:

$x_1 + x_2 + 2x_3 = 0$	$x_1 + x_2 + 2x_3 = 1$	$x_1 + x_2 + 2x_3 = 2$
0 0 0	0 0 2	0 0 1
0 1 1	0 1 0	0 1 2
0 2 2	0 2 1	0 2 0
1 0 1	1 0 0	1 0 2
1 1 2	1 1 1	1 1 0
1 2 0	1 2 2	1 2 1
2 0 2	2 0 1	2 0 0
2 1 0	2 1 2	2 1 1
2 2 1	2 2 0	2 2 2

Por consiguiente, los cuatro efectos que en realidad se estiman a partir de los ocho grados de libertad del diseño son: $A + B^1C^2 + A^1B^2C^1, B + A^1C^2 + A^1B^2C^2, C + A^1B^1 + A^1B^1C^1$ y $A^1B^2 + A^1C^1 + B^1C^1$. Este diseño solo tendría valor práctico si todas las interacciones fueran pequeñas en comparación con los efectos principales. Puesto que los efectos principales son alias de las interacciones de dos factores, se trata de un diseño de resolución III que es el de menor resolución.

El supuesto de las interacciones insignificantes, requerido para la interpretación única del diseño 3_{III}^{k-1} , tiene su paralelo en el diseño de cuadrado latino. Sin embargo, los dos diseños surgen por motivos diferentes: uno como consecuencia de la réplica fraccionada y el otro de la restricción en la aleatorización.

El análisis estadístico de un diseño 3^{k-1} se lleva a cabo con los procedimientos usuales del análisis de varianza para experimentos factoriales. Las sumas de cuadrados pueden calcularse como se presentó en los capítulos 9 y 10. En la interpretación de los resultados, se debe recordar que los componentes de las interacciones no tienen interpretación práctica.

11.1.5.1. Diseños factoriales fraccionados 3^{k-p}

Para moderar los valores grandes de k , es deseable un fraccionamiento todavía mayor del diseño 3^k . En general, puede construirse un factorial fraccionado 3^{k-p} . Por ejemplo, un diseño 3^{k-2} es una fracción un noveno, un diseño 3^{k-3} es una fracción un veintisieteavo, etc.

El procedimiento para construir un diseño factorial fraccionado 3^{k-p} consiste en seleccionar p componentes de interacciones y usar estos efectos para hacer la partición de las 3^k combinaciones de tratamientos en 3^p bloques de igual tamaño. En este caso, cada bloque es un diseño factorial fraccionado 3^{k-p} . La relación de definición I de cualquier fracción consta de los p efectos elegidos inicialmente y sus $(3^p - 2p - 1)/2$ interacciones generalizadas. El alias de cualquier efecto principal o componente de interacción se obtiene con la multiplicación módulo 3 del efecto por I e I^2 (módulo 3).

Por ejemplo, si se desea construir un diseño 3^{4-2} , es decir, una fracción un noveno del diseño 3^4 , se considera $A^1B^1C^2$ y $A^1B^2D^2$ los dos componentes de interacciones elegidos para construir el diseño. Sus interacciones generalizadas son $(A^1B^1C^2)(A^1B^2D^2) = A^2C^2D^2 = A^1C^1D^1$ y $(A^1B^1C^2)(A^1B^2D^2)^2 = B^2C^2D^1 = B^1C^1D^2$. Por lo tanto, la relación de definición de este diseño es $I = A^1B^1C^2 = A^1B^2D^2 = A^1C^1D^1 = B^1C^1D^2$, es un diseño de resolución III. Las nueve combinaciones de tratamientos del diseño se encuentran colocando un diseño 3^2 en los factores A y B , y agregando después dos nuevos factores. Esto es equivalente a usar $A^1B^1C^2$ y $A^1B^2D^2$ para hacer la partición del diseño 3^4 completo en nueve bloques y luego seleccionar uno de estos bloques como la fracción deseada. El diseño completo con estas características es el siguiente:

0000	0112	0221
1011	1120	1202
2022	2101	2210

Este diseño tiene ocho grados de libertad, los cuales pueden usarse para determinar cuatro efectos principales y sus alias. Los alias de cualquier efecto pueden encontrarse multiplicando el efecto módulo 3 por $A^1B^1C^2$, $A^1B^2D^2$, $A^1C^1D^1$, $B^1C^1D^2$, $(A^1B^1C^2)^2$, $(A^1C^1D^1)^2$ y $(B^1C^1D^2)^2$. En la tabla 11.7, se presenta la estructura completa de alias del diseño propuesto.

De la estructura anterior de alias, se observa que este diseño es útil en ausencia de interacciones.

En esta sección se ha hecho notar la complejidad de las relaciones de los alias de los diseños factoriales fraccionado 3^{k-p} . En general, si k es moderadamente grande, por ejemplo $k \geq 4$ o 5, el tamaño del diseño 3^k llevará a muchos experimentadores a considerar fracciones bastante pequeñas. Desafortunadamente, estos diseños tienen relaciones de alias que incluyen *alias parciales* de componentes de interacciones con dos grados de libertad. Esto, a su vez, resulta en un diseño cuya interpretación será difícil, si no imposible, si las interacciones no son significativas, luego estos diseños deben usarse con precaución.

Tabla 11.7: Estructura de alias del diseño factorial fraccionado 3_{III}^{4-2}

Efecto	Alias			
	<i>I</i>			
<i>A</i>	$A^1B^2C^1$	$A^1B^1D^1$	$A^1C^2D^2$	$A^1B^1C^1D^2$
<i>B</i>	$A^1B^2C^2$	A^1D^2	$A^1B^1C^1D^1$	$B^1C^2D^1$
<i>C</i>	A^1B^1	$A^1B^2C^1D^2$	$A^1C^2D^1$	$B^1C^2D^2$
<i>D</i>	$A^1B^1C^2D^1$	A^1B^2	$A^1C^1D^2$	$B^1C^1D^2$
	<i>I</i> ²			
<i>A</i>	B^1C^2	B^1D^1	C^1D^1	$A^1B^2C^2D^1$
<i>B</i>	A^1C^2	$A^1B^1D^2$	$A^1B^2C^1D^1$	C^1D^2
<i>C</i>	$A^1B^1C^1$	$A^1B^2C^2D^1$	A^1D^1	B^1D^2
<i>D</i>	$A^1B^1C^2D^2$	$A^1B^2D^1$	A^1C^1	$B^1C^1D^1$

11.2. Diseño en parcelas divididas y subdivididas

En todos los diseños presentados hasta ahora, el error que se ha tenido en cuenta es el generado por la unidades experimentales (UE) a las cuales se le asigna un tratamiento, el cual se genera en el proceso de aleatorización. Sin embargo, en muchas situaciones prácticas, para un experimento factorial diferentes tipos de UE son usadas y los niveles de los mismos factores son aplicados secuencialmente, separando los procesos de aleatorización. En el caso más simple, se tienen UE de un tamaño para los niveles de un factor, luego estas UE son subdivididas en UEs más pequeñas a las cuales los niveles del segundo factor son aplicados. Este proceso se conoce como el de *parcelas divididas (PD)* y *subdivididas (PSD)*.

Los diseños en *parcelas divididas* y *subdivididas* se emplean frecuentemente en experimentos factoriales en los cuales las condiciones del material experimental o las operaciones experimentales contempladas dificultan el manejo de toda la combinación de factores. El diseño básico de *PD* involucra la asignación de tratamientos de un factor a *parcelas principales (PP)* o *parcelas grandes*, las cuales se disponen en diseños experimentales clásicos. Los tratamientos del segundo factor (generalmente niveles) se asignan a *subparcelas* que se aleatorizan dentro de la *PP*. El diseño básico de *PD* involucra la asignación de tratamientos de un factor a la *PP*, dispuestos en un DCA, DBCA o DCL, entre otros.

En este diseño, se suele sacrificar la precisión en la estimación de los efectos promedio de los tratamientos en el factor asignado a las *PP*. Aunque frecuentemente se incrementa la precisión para comparar los efectos promedio de tratamientos asignados a las *subparcelas (SP)*, así como cuando existen interacciones para comparar los efectos de tratamientos de *SP* con un tratamiento de una *PP*. Esto se desprende del hecho de que el error experimental de las parcelas principales va a ser siempre mayor que el error experimental de las subparcelas ($EE_{PP} > EE_{SP}$).

Observación 11.2. A menudo el término de error para *SP* es inferior al que se obtiene si todas las combinaciones de tratamientos se disponen en DBCA.


Por ejemplo, en una investigación agrícola las parcelas completas son áreas extensas de tierra, las cuales son divididas dentro de *SP*, es decir, áreas más pequeñas dentro de las áreas extensas, diversas variedades de un cultivo podrán sembrarse en diferentes campos (parcelas completas), una variedad por campo. Después cada campo puede dividirse en, por ejemplo, cuatro subparcelas y cada subparcela puede tratarse con un tipo diferente de fertilizante. En este caso, las variedades son los tratamientos principales (*PP*) y los diferentes fertilizantes son los subtratamientos (*SP*). Las hipótesis sobre las *SP* son juzgadas con mayor precisión que las de las *PP* debido a que es mayor la homogeneidad entre *SP* que entre las *PP*.

Según Steel y Torrie (1982), se recomienda el uso de *PD* en los siguientes casos:

- a. Cuando los niveles de uno o más factores requieren gran cantidad de material experimental por UE frente a otros factores. Esto es común en experimentación realizada en el campo (por ejemplo, experimentación agrícola), en ensayos de laboratorio, en el área industrial, medicina, entre otras. Como ejemplo se tienen las siguientes situaciones: uso de riego, métodos de preparación del suelo o aplicación de fertilizantes, variedades de una planta etc.; sería más factible usarlos como *PP* que como *SP*.
- b. Cuando se desea incorporar algún factor adicional para aumentar el alcance del experimento. Por ejemplo, si se desean incorporar ciertos fungicidas para incrementar el alcance de la investigación, se puede proponer variedades que presenten diversos tipos de resistencia a las enfermedades. En este caso, el uso de variedades como *PP* daría más proyección al experimento.

- c. Tiene gran utilidad cuando se desea que ciertos factores sean medidos con mayor precisión que otros. En este caso, se elige como *SP* los factores que se desea estudiar con mayor precisión.

Un diagrama de una *PD* en bloques es el siguiente:



11.2.1. Análisis estadístico del diseño en parcelas divididas

Para diseñar parcelas divididas se usa una formulación de modelo mixto el cual permite reflejar las distintas varianzas del error experimental para las *SP* y la *PP*, lo que incluye los efectos del error aleatorio por separado para ambas. Si el factor de tratamiento de la *PP* se coloca en un DBCA, el modelo lineal estadístico es:

$$y_{ijk} = \mu + \alpha_i + \delta_k + \eta_{ik} + \beta_j + \alpha\beta_{ij} + e_{ijk}, \quad (11.1)$$

con $i = 1, 2, \dots, I$, $j = 1, 2, \dots, J$ y $k = 1, 2, \dots, K$, donde μ es la media general, α_i es el efecto del i -ésimo nivel del factor A , δ_k es el efecto del k -ésimo bloque, η_{ik} es el error aleatorio de la *PP*, β_j se asocia al efecto del j -ésimo nivel del factor B , $(\alpha\beta)_{ij}$ es la interacción entre los dos factores y e_{ijk} es el error aleatorio de la *SP*.

Se supone que los errores de la *PP* y la *SP* son aleatorios e independientes, con distribución normal con media cero y varianzas σ_η^2 y σ_e^2 , respectivamente. La asignación aleatoria de los tratamientos a las UE justifica el supuesto de independencia para los errores aleatorios y la correlación igual entre los errores de las unidades en la *SP* dentro de una misma *PP*.

Para estimar los parámetros en el modelo (11.1), se utiliza el método de mínimos cuadrados, obteniéndose la siguiente expresión a minimizar:

$$L = \sum_{ijk} \hat{e}_{ijk}^2 = \sum_{ijk} \left(y_{ijk} - \hat{\mu} - \hat{\alpha}_i - \hat{\delta}_k - \hat{\eta}_{ik} - \hat{\beta}_j - \widehat{\alpha\beta}_{ij} \right)^2.$$

Al derivar la anterior expresión con respecto a cada uno de los parámetros involucrados y al imponer las siguientes restricciones de no estimabilidad

$$\sum_{i=1}^I \alpha_i = \sum_{k=1}^K \delta_k = \sum_{i=1}^I \eta_{ik} = \sum_{k=1}^K \eta_{ik} = \sum_{j=1}^J \beta_j = \sum_{i=1}^I \alpha \beta_{ij} = \sum_{j=1}^J \alpha \beta_{ij} = 0,$$

se obtienen los siguientes estimadores de los parámetros:

$$\begin{aligned} \hat{\mu} &= \frac{y_{...}}{IJK} = \bar{y}_{...} & \hat{\alpha}_i &= \frac{y_{i..}}{JK} - \hat{\mu} = \bar{y}_{i..} - \bar{y}_{...} \\ \hat{\delta}_k &= \frac{y_{..k}}{IJ} - \hat{\mu} = \bar{y}_{..k} - \bar{y}_{...} & \hat{\eta}_{ik} &= \frac{y_{i.k}}{J} - \hat{\mu} - \hat{\alpha}_i - \hat{\delta}_k \\ \hat{\beta}_j &= \frac{y_{.j.}}{IK} - \hat{\mu} = \bar{y}_{.j.} - \bar{y}_{...} & \widehat{\alpha\beta}_{ij} &= \frac{y_{ij.}}{K} - \hat{\mu} - \hat{\alpha}_i - \hat{\beta}_j, \end{aligned}$$

para $i = 1, 2, \dots, I$, $j = 1, 2, \dots, J$ y $k = 1, 2, \dots, K$.

En la tabla 11.8 de análisis de varianza, se presenta la esperanza de los cuadrados medios para los componentes del modelo (11.1), obtenida a partir de los resultados propuestos para los modelos mixtos presentados en el capítulo 4, en este caso A y B se consideran fijos.

Tabla 11.8: Análisis de varianza para el diseño en bloques en parcelas divididas

C de V	gl	SC	E(CM)
Bloques	$K - 1$	$SC(\text{Bloques})$	
Factor A	$I - 1$	$SC(A)$	$\sigma_e^2 + J\sigma_\eta^2 + \frac{JK}{I-1} \sum_{i=1}^I \alpha_i^2$
Error(A)	$(K - 1)(I - 1)$	$SCE(A)$	$\sigma_e^2 + J\sigma_\eta^2$
Factor B	$J - 1$	$SC(B)$	$\sigma_e^2 + \frac{IK}{J-1} \sum_{j=1}^J \beta_j^2$
AB	$(I - 1)(J - 1)$	$SC(AB)$	$\sigma_e^2 + \frac{K}{(I-1)(J-1)} \sum_{ij} (\alpha\beta)_{ij}^2$
Error(B)	$I(J - 1)(K - 1)$	$SCE(B)$	σ_e^2
Total	$IJK - 1$	SCT_{CM}	

Las diferentes sumas de cuadrados presentadas en la tabla 11.8 son:

$$\begin{aligned} SC(\text{Bloques}) &= \frac{1}{IJ} \sum_{k=1}^K y_{..k}^2 - \frac{y_{...}^2}{IJK} \\ SC(A) &= \frac{1}{JK} \sum_{i=1}^I y_{i..}^2 - \frac{y_{...}^2}{IJK} \\ SCE(A) &= \frac{1}{J} \sum_{ik} y_{i.k}^2 - \frac{1}{JK} \sum_{i=1}^I y_{i..}^2 - \frac{1}{IJ} \sum_{k=1}^K y_{..k}^2 + \frac{y_{...}^2}{IJK} \end{aligned}$$

$$SC(B) = \frac{1}{IK} \sum_{j=1}^J y_{.j}^2 - \frac{y_{...}^2}{IJK}$$

$$SC(AB) = \frac{1}{K} \sum_{ij} y_{ij}^2 - \frac{1}{JK} \sum_i y_{i..}^2 - \frac{1}{IK} \sum_{j=1}^J y_{.j}^2 + \frac{y_{...}^2}{IJK}$$

$$SCT_{CM} = \sum_{ijk} y_{ijk}^2 - \frac{y_{...}^2}{IJK}$$

$$SCE(B) = SCT_{CM} - SC(Bloques) - SC(A) - SCE(A) - SC(B) - SC(AB).$$

Los cuadrados medios esperados para el error(A) y el error(B) reflejan las diferencias en la variabilidad para los dos tipos de unidades experimentales PP y SP . Las varianzas del error esperadas para las PP son mayores que las de las SP .

La forma de los $E(CM)$ indica los estadísticos de prueba apropiados para juzgar las hipótesis nulas de interacción y de efectos principales. Estas son:

- a. H_0 : todos los $(\alpha\beta)_{ij} = 0$ contra H_a : al menos un $(\alpha\beta)_{ij} \neq 0$ para algún i, j ($i = 1, \dots, I, j = 1, \dots, J$). El estadístico de prueba es:

$$F_{AB} = \frac{\frac{SC(AB)}{(I-1)(J-1)}}{\frac{SCE(B)}{I(J-1)(K-1)}} = \frac{CM(AB)}{CME(B)} \sim F_{((I-1)(J-1), I(J-1)(K-1))}.$$

- b. H_0 : $\beta_1 = \beta_2 = \dots = \beta_J = 0$ contra H_a : al menos un $\beta_j \neq 0$ para alguna $j = 1, \dots, J$. El estadístico de prueba es:

$$F_B = \frac{\frac{SC(B)}{J-1}}{\frac{SCE(B)}{I(J-1)(K-1)}} = \frac{CM(B)}{CME(B)} \sim F_{(J-1, I(J-1)(K-1))}.$$

- c. H_0 : $\alpha_1 = \alpha_2 = \dots = \alpha_I = 0$ contra H_a : al menos un $\alpha_i \neq 0$ para alguna $i = 1, \dots, I$. El estadístico de prueba es:

$$F_A = \frac{\frac{SC(A)}{I-1}}{\frac{SCE(A)}{(I-1)(K-1)}} = \frac{CM(A)}{CME(A)} \sim F_{(I-1, (I-1)(K-1))}.$$

Ejemplo 11.3. Se realizó un experimento para comparar el rendimiento de dos variedades de arroz sembradas en dos parcelas diferentes. Dentro de las parcelas se hicieron subparcelas para comparar el efecto de tres fechas de siembra sobre la producción de arroz y se consideraron dos replicaciones (bloques), teniendo en cuenta la pendiente del suelo. Los datos se presentan a continuación:

Réplica I				Réplica II			
Variedad 1		Variedad 2		Variedad 1		Variedad 2	
F1	5.0	F3	6.5	F1	5.4	F2	6.5
F2	5.3	F1	5.7	F3	6.4	F3	6.6
F3	5.8	F2	6.0	F2	5.9	F1	5.8

Las diferentes sumas de cuadrados para este conjunto de datos son:

$$SC(Réplica) = \frac{34.3^2 + 36.6^2}{6} - \frac{70.9^2}{12} = 0.44$$

$$SC(Variedad) = \frac{33.8^2 + 37.1^2}{6} - \frac{70.9^2}{12} = 0.91$$

$$SCE(V) = \frac{16.1^2 + 18.2^2 + 17.7^2 + 18.9^2}{3} - 419.34 - 419.81 + \frac{70.9^2}{12} = 0.07$$

$$SC(Fechas) = \frac{21.9^2 + 23.7^2 + 25.3^2}{4} - \frac{70.9^2}{12} = 1.45$$

$$SC(VF) = \frac{10.4^2 + 11.2^2 + \dots + 13.1^2}{2} - 419.81 - 420.35 + \frac{70.9^2}{12} = 0.02$$

$$SCT_{CM} = 5.0^2 + 5.3^2 + \dots + 6.6^2 + 5.8^2 - \frac{70.9^2}{12} = 2.95$$

$$SCE(F) = 2.95 - 0.44 - 0.91 - 0.07 - 1.45 - 0.02 = 0.06.$$

Con base en los anteriores resultados, se construye la tabla 11.9 de análisis de varianza para la información presentada. La interacción entre variedad y fecha no es significativa (valor $p = 0.592$) y el efecto de la variedad tampoco lo es (valor $p = 0.169$). En cambio, la fecha de siembra es significativa (valor $p = 0.002$).

Tabla 11.9: Análisis de varianza para el rendimiento en la producción de arroz

C de V	gl	SC	CM	F	Valor p
Réplica	1	0.44	0.44		
Variedad	1	0.91	0.91	13.44	0,169
Error(V)	1	0.07	0.07		
Fecha	2	1.45	0.72	43,40	0,002
V*F	2	0,02	0.01	0.60	0.592
Error(F)	4	0.07	0,02		
Total	11	2.95			

Las medias de celda y las medias marginales para la fuente variedad y las fechas se presentan en la tabla 11.10.

Tabla 11.10: Rendimientos en la producción de arroz por variedad y fecha

	F1	F2	F3	Medias por variedad
V1	5.20	5.60	6.10	5.63
V2	5.75	6.15	6.55	6.15
Medias por fecha	5.48	5.88	6.33	

En la figura 11.1, se muestra el rendimiento medio en la producción de arroz en las diferentes fechas de siembra. Como se observa en la gráfica, al igual que en las pruebas estadísticas, no hay interacción entre los dos factores involucrados ni diferencias importantes entre variedades; se llega a la conclusión de que hay un incremento en el rendimiento cuando la fecha de siembra aumenta.




Figura 11.1: Interacción entre variedad y fecha de siembra en el rendimiento de producción promedio de arroz.

11.2.2. Eficiencia relativa de un diseño de parcelas divididas

Bajo muchas circunstancias, el diseño en parcelas divididas es usado por razones técnicas y prácticas, puesto que los niveles de algunos factores son aplicados a las UE grandes, las cuales son parcelas dentro de UE más pequeñas para la aplicación del otro factor. Por lo tanto, se hace necesario evaluar la eficiencia del diseño, por ejemplo, en parcelas divididas con respecto a un diseño en bloques con dos factores. Para hacer esta evaluación, se debe conocer el *CME* de este para determinar la cantidad de información que

se debe tener en cuenta en la comparación de los tratamientos. En la tabla 11.11, se presenta el ANOVA cuando se tienen dos factores en investigación en un diseño en bloques.

Tabla 11.11: Análisis de varianza para el diseño factorial con dos factores en bloques

C de V	gl	SC	CM
Bloques	$K - 1$	$SC(Bloques)$	
Factor A	$I - 1$	$SC(A)$	$CM(A)$
Factor B	$J - 1$	$SC(B)$	$CM(B)$
AB	$(I - 1)(J - 1)$	$SC(AB)$	$CM(AB)$
Error	$(IJ - 1)(K - 1)$	SCE_F	CME_F

Comparando las tablas de análisis de varianza 11.8 con 11.11, se encuentra que

$$\begin{aligned} SCE_F &= (IJ - 1)(K - 1)CME_F \\ &= (I - 1)(K - 1)CME(A) + I(J - 1)(K - 1)CME(B) \end{aligned}$$

y, por consiguiente, el cuadrado medio del error en el caso de arreglos factoriales es:

$$CME_F = \frac{(I - 1)CME(A) + I(J - 1)CME(B)}{IJ - 1}.$$

De lo anterior, la eficiencia relativa del diseño factorial en bloques con respecto al diseño en parcelas divididas es:

$$\begin{aligned} ER &= \frac{CME_F}{CME(B)} = \frac{I(J - 1)}{IJ - 1} + \frac{I - 1}{IJ - 1} \frac{CME(A)}{CME(B)} \\ &= 1 + \frac{I - 1}{IJ - 1} \left(\frac{CME(A)}{CME(B)} - 1 \right). \end{aligned}$$

De este resultado, se puede concluir que:

- Si $CME(A) = CME(B)$, entonces $ER = 1$, siendo igualmente eficientes los dos diseños. Cuando esto pasa, posiblemente se prefiera el diseño factorial en bloques en cambio del diseño en parcelas divididas.
- Si $CME(A) < CME(B)$, entonces $ER < 1$, luego el diseño factorial es más eficiente.
- Si $CME(A) > CME(B)$, entonces $ER > 1$ y, por consiguiente, el diseño factorial es menos eficiente que parcelas divididas.

11.3. Implementación en SAS

A partir de los datos de los ejemplos 11.1, 11.2 y 11.3 presentados a lo largo del capítulo, se presentan a continuación los programas en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos.

```
/* Diseño factorial fraccionado 2^{4-1} */

/* Lectura de los datos del ejemplo 11.1 */

DATA EJEMPLO111;
INPUT A B C D REND @@;
CARDS;
-1 -1 -1 -1 7 1 -1 -1 1 10 -1 1 -1 1 32 1 1 -1 -1 55
-1 -1 1 1 18 1 -1 1 -1 20 -1 1 1 -1 40 1 1 1 1 61
;

/* Se proyecta el diseño 2^{4-1} en uno 2^3 enviando los efectos no
importantes al error experimental */

PROC GLM DATA=EJEMPLO111;
CLASS A B C;
MODEL REND=A B A*B C;

/* Diseño factorial fraccionado 2^{7-4} en dos bloques */
/* Lectura de los datos del ejemplo 11.2 */

DATA EJEMPLO112;
INPUT A B C D E F G BLOQUE TF;
CARDS;
-1 -1 -1 -1 1 1 1 1 68.4
1 -1 -1 1 -1 -1 1 1 77.7
-1 1 -1 1 -1 1 -1 1 66.4
1 1 -1 -1 1 -1 -1 1 81.0
-1 -1 1 1 1 -1 -1 1 78.6
1 -1 1 -1 -1 1 -1 1 41.2
-1 1 1 -1 -1 -1 1 1 68.7
1 1 1 1 1 1 1 1 38.7
1 1 1 1 -1 -1 -1 2 66.7
-1 1 1 -1 1 1 -1 2 65.0
1 -1 1 -1 1 -1 1 2 86.4
-1 -1 1 1 -1 1 1 2 61.9
1 1 -1 -1 -1 1 1 2 47.8
-1 1 -1 1 1 -1 1 2 59.0
1 -1 -1 1 1 1 -1 2 42.6
-1 -1 -1 -1 -1 -1 -1 2 67.6
;
```

```
/* En el diseño 2^{7-4} en dos bloques se envía los efectos no importantes
al error experimental y se considera el efecto del bloque */
```

```
PROC GLM DATA=EJEMPLO112;
CLASS A B C D E F G BLOQUE;
MODEL TF=A F A*F BLOQUE;
```

```
/* Diseño en parcelas divididas y subdivididas con bloques */
```

```
/* Lectura de los datos del ejemplo 11.3 */
```

```
DATA EJEMPLO113;
INPUT REPLICA VARIEDAD FECHA RENDIMIENTO @@;
CARDS;
1 1 1 5.0 1 1 2 5.3 1 1 3 5.8 1 2 3 6.5 1 2 1 5.7 1 2 2 6.0
2 1 1 5.4 2 1 3 6.4 2 1 2 5.9 2 2 2 6.5 2 2 3 6.6 2 2 1 5.8
;
```

```
/* Al hacer aleatoria la interacción RÉPLICA*VARIEDAD y con la opción
TEST se realiza el análisis de varianza en parcelas divididas y
subdivididas en las réplicas */
```

```
PROC GLM DATA=EJEMPLO113;
CLASS REPLICA VARIEDAD FECHA;
MODEL RENDIMIENTO=REPLICA VARIEDAD REPLICA*VARIEDAD FECHA
VARIEDAD*FECHA;
RANDOM REPLICA*VARIEDAD/TEST;
RUN;
```

11.4. Implementación en R

A partir de los datos de los ejemplos [11.1](#), [11.2](#) y [11.3](#), se presenta a continuación el programa en el software estadístico R.

```
#####
## Ejemplo 11.1 ##
#####

ejemplo11.1 <- data.frame(A=factor(c(-1, 1, -1, 1, -1, 1, -1,1)),
B=factor(c(-1, -1, 1, 1, -1, -1, 1,1)),
C=factor(c(-1, -1, -1, -1, 1, 1, 1,1)),
D=factor(c(-1,1,1,-1,1,-1,-1,1)),
rendimiento=c(7,10,32,55,18,20,40,61))
modelo11.1 <- aov(rendimiento~A*B+C,data=ejemplo11.1)
summary(modelo11.1)
summary(lm(modelo11.1))
```

```
#####
## Ejemplo 11.2 ##
#####
```

```
ejemplo11.2 <- data.frame(A=factor(c(-1,1,-1,1,-1,1,-1,1,1,-1,1,-1,1,
-1)),
B=factor(c(-1, -1, 1, 1, -1, -1, 1,1, 1, 1, -1, -1, 1, 1, -1,-1)),
C=factor(c(-1, -1, -1, -1, 1, 1, 1,1,1, 1, 1, 1, -1, -1, -1,-1)),
D=factor(c(-1,1,1,-1,1,-1,-1,1,1,-1,-1,1,-1,1,1,-1)),
E=factor(c(1,-1,-1,1,1,-1,-1,1,-1,1,1,-1,-1,1,1,-1)),
F=factor(c(1,-1,1,-1,-1,1,-1,1,-1,1,1,-1,1,1,-1,-1)),
G=factor(c(1,1,-1,-1,-1,-1,1,1,-1,-1,1,1,1,1,-1,-1)),
bloque=factor(rep(c(rep(1,8),rep(2,8)))),
tiempofiltro=c(68.4,77.7,66.4,81,78.6,41.2,68.7,38.7,66.7,65,86.4,61.9,47.8,
59,42.6,67.6))
```

```
modelo11.2 <-aov(tiempofiltro~A*F+bloque,data=ejemplo11.2)
summary(modelo11.2)
summary(lm(modelo11.2))
```

```
#####
## Ejemplo 11.3 ##
#####
```

```
ejemplo11.3 <- data.frame(replica=factor(rep(c(rep(1,6),rep(2,6)))),
variedad=factor(c(rep(1,3),rep(2,3),rep(1,3),rep(2,3))),
fecha=factor(c(1,2,3,3,1,2,1,3,2,2,3,1)),
parcela=factor(c(1,1,1,2,2,2,3,3,3,4,4,4)),
produccion=c(5.0,5.3,5.8,6.5,5.7,6.0,5.4,6.4,5.9,6.5,6.6,5.8))
```

```
modelo11.3 <-aov(produccion~replica+variedad*fecha+Error(parcela),
data=ejemplo11.3)
summary(modelo11.3)
```

```
interaction.plot(ejemplo11.3$fecha,ejemplo11.3$variedad,ejemplo11.3$
produccion,col=1,xlab='Fecha',ylab='Producción promedio',leg.bty='o',
cex=1.5)
```

```
# Grados de libertad del error parcela principal
gl.error.a<-1
# Grados de libertad del error suparcela
gl.error.b <-modelo11.3$Within$df.residual
# Residuos
x <-modelo11.3$parcela$residuals
y <-modelo11.3$Within$residuals
# Suma de cuadrados del error parcela principal
sc.error.a <-sum(x^2)
# Suma de cuadrados del error subparcela
sc.error.b <-sum(y^2)
```

```
# Cuadrado medio del error parcela principal
cm.a <-sc.error.a
# Cuadrado medio del error de subparcela
cm.b <-sc.error.b/gl.error.b

library(agricolae)
# Comparación múltiple de Honestly Significant Difference
HSD.test(ejemplo11.3$produccion,ejemplo11.3$fecha,gl.error.b,cm.b,
group=TRUE,console=TRUE)
```

11.5. Ejercicios

1. Analice los datos del ejercicio 6 del capítulo 9 como si provinieran de un diseño 2^{3-1}_{III} , con $I = -ABC$. Construya el diseño, obtenga la estructura de alias y analice los resultados obtenidos.
2. Repita el ejercicio anterior utilizando $I = ABC$. ¿El uso de esta fracción modifica la interpretación del diseño?
3. Construya un diseño 2^{7-2} ; indique cómo puede realizarse el diseño en cuatro bloques de ocho observaciones cada uno (determine el tipo de resolución). ¿Determine si alguno de los efectos principales o de las interacciones de dos factores están confundidos con los bloques?
4. Considere un experimento factorial 2^7 y suponga que el experimentador tiene solamente suficientes tratamientos para realizar una fracción. La fracción seleccionada es la que se obtiene de la relación de definición $I = +ABCD = +ADEF = +CEFG$.
 - a. Presente el conjunto de tratamientos y alias que se obtienen en esta fracción.
 - b. Asuma que todas las interacciones de 3 o más factores y todas las interacciones de dos factores que no involucran el factor B no son importantes, muestre que todos los efectos principales e interacciones de dos factores, involucrando el factor B , pueden estimarse del factorial fraccionado.
 - c. Suponga que se tienen dos observaciones (es decir, dos unidades experimentales) por cada tratamiento en un DCA. Obtenga la tabla de análisis de varianza (presentando las causas de variación, grados de libertad y $E(CM)$) con base en los supuestos realizados en el ítem b.

- d. Considere que se necesitan bloques de tamaño 8 y se tienen 4 bloques disponibles; bajo los supuestos dados en b., presente un arreglo factorial sin sacrificar información sobre efectos principales e interacciones entre dos factores involucrando el factor B .
 - e. Para el diseño en d., obtenga la tabla de análisis de varianza (causas de variación y grados de libertad).
 - f. Realice un programa en SAS para obtener los resultados presentados en e.
 - g. Realice un programa en R para obtener los resultados presentados en e.
5. En Montgomery (2003) se presenta un caso en el que se estudia el tratamiento térmico, el cual es de uso común para carbonizar piezas metálicas, como engranes. Por ejemplo, el espesor de la capa carbonizada es una variable de salida crítica de este proceso y suele medirse realizando un análisis de carbono del paso del engrane (la cara superior del diente del engrane). Se estudiaron seis factores en un diseño 2^{6-2}_{IV} , estos fueron A = temperatura del horno, B = duración del ciclo, C = concentración de carbono, D = duración del ciclo de carbonización, E = concentración de carbono del ciclo difuso y F = duración del ciclo difuso. Los resultados del experimento se presentan en la tabla 11.12.

Tabla 11.12: Espesor de la capa carbonizada

A	B	C	D	E	F	Paso
–	–	–	–	–	–	74
+	–	–	–	+	–	190
–	+	–	–	+	+	133
+	+	–	–	–	+	127
–	–	+	–	+	+	115
+	–	+	–	–	+	101
–	+	+	–	–	–	54
+	+	+	–	+	–	144
–	–	–	+	–	+	121
+	–	–	+	+	+	188
–	+	–	+	+	–	135
+	+	–	+	–	–	170
–	–	+	+	+	–	126
+	–	+	+	–	–	175
–	+	+	+	–	+	126
+	+	+	+	+	+	193

- a. Obtenga el conjunto de alias generados por esta fracción.
 - b. Estime los efectos de los factores y seleccione un modelo tentativo para el análisis de varianza.
 - c. Efectúe las pruebas estadísticas apropiadas.
 - d. Analice los residuales y discuta sobre el adecuado ajuste del modelo.
 - e. Interprete los resultados de este experimento. Suponga que es deseable un espesor de la capa entre 140 y 160.
 - f. ¿Cómo llevaría el análisis haciendo uso de R y SAS?
6. Considere los datos del ejercicio 9 del capítulo 9. Suponga que solo se realiza la fracción un tercio de este experimento, con $I = A^1B^2C^1$. Construya el diseño, determine la estructura de alias y analice los datos.
 7. Obtenga los tratamientos y la estructura de alias para la fracción $1/3$ del factorial completo 3^4 con $I = A^1B^2C^2D^2$ de resolución IV (asuma que las interacciones de tres y cuatro factores no son importantes).
 8. Construya un diseño factorial fraccionado 3^{6-2} , con $A^1B^2C^2D^2$ y $B^1D^2E^1F^2$. Obtenga los tratamientos y la estructura de alias. ¿Cuál es la resolución de este diseño?
 9. Suponga que un investigador en fisiología está interesado en planear un experimento para medir el efecto del área necrótica sobre la fotosíntesis de 8 variedades de café susceptibles a la roya. Planea usar parcelas experimentales de 4 plantas en un lote ubicado en una pendiente del 70 %. Por experimentos anteriores, se sabe que la roya es más agresiva en las zonas bajas que, en este caso, además son las más húmedas y, por lo tanto, más favorables para el desarrollo de la enfermedad. El investigador cuenta con 320 plantas y solo puede sembrar grupos de 32 plantas para distribuir las a lo largo de la pendiente. Por otra parte, cuenta con 8 equipos para medir la fotosíntesis, por esto se decide medir únicamente entre las 10:00 y 10:15 a.m. Se sabe que tarda en medir la fotosíntesis de cada hoja afectada 3 minutos. ¿Qué diseño experimental le recomendaría al investigador? De acuerdo con lo recomendado, señale cómo hacer el análisis de la información y las comparaciones de tratamientos, de forma general.
 10. La tabla 11.13 presenta la producción de granos de cuatro variedades de arroz cuando se aplican seis niveles de nitrógeno en un diseño de parcelas divididas con tres replicaciones.

Tabla 11.13: Producción de granos en Kg/Ha

Variedad	Réplica I	Réplica II	Réplica III
N_0 (0 Kg N/Ha)			
V_1 (IR8)	4.430	4.478	3.850
V_2 (IR5)	3.944	5.314	3.660
V_3 (C4 – 63)	3.464	2.944	3.142
V_4 (Peta)	4.126	4.482	4.836
N_1 (60 Kg N/Ha)			
V_1	5.418	5.166	6.432
V_2	6.502	5.858	5.586
V_3	4.768	6.004	5.556
V_4	5.192	4.604	4.652
N_2 (90 Kg N/Ha)			
V_1	6.076	6.420	6.704
V_2	6.008	6.127	6.642
V_3	6.244	5.724	6.014
V_4	4.546	5.744	4.146
N_3 (120 Kg N/Ha)			
V_1	6.462	7.056	6.680
V_2	7.139	6.982	6.564
V_3	5.792	5.880	6.370
V_4	2.774	5.036	3.638
N_4 (150 Kg N/Ha)			
V_1	7.290	7.848	7.552
V_2	7.682	6.594	6.576
V_3	7.080	6.662	6.320
V_4	1.414	1.960	2.766
N_5 (180 Kg N/Ha)			
V_1	8.452	8.832	8.818
V_2	6.228	7.387	6.006
V_3	5.594	7.122	5.480
V_4	2.248	1.380	2.014

- Describa este experimento como un proyecto de investigación. Escriba objetivos, población, factores, niveles, unidades experimentales, variable de respuesta, tamaño del experimento y explique en qué consisten las replicaciones.
- Defina una forma de aleatorizar el experimento.
- Cite dos condiciones del experimento que ayuden al control del error experimental.
- Caracterice completamente este diseño (establezca el modelo del diseño, si son efectos fijos o aleatorios, diseño balanceado o desbalanceado).
- Formule las hipótesis de interés.

- f. Realice la tabla de ANOVA correspondiente y concluya.
 - g. Construya las esperanzas de los cuadrados medios, estime las componentes de varianza correspondientes e intérprete sus resultados.
 - h. Es eficiente este diseño en comparación con uno factorial.
 - i. Realice la prueba de comparaciones múltiples de Tukey, Duncan y concluya.
 - j. Verifique los supuestos del modelo teniendo en cuenta los residuos estudentizados y concluya.
 - k. Realice todo el análisis usando R y SAS.
11. a. ¿Cuántos grados de libertad tiene el error experimental en un diseño de parcelas divididas en 4 bloques completos aleatorizados, donde se tienen 3 parcelas principales y 3 subparcelas?
- b. Si los factores asociados con las parcelas divididas del ítem a. son cuantitativos. ¿Cómo realizaría el análisis?
- c. Escriba el modelo correspondiente al diseño y dé el significado de cada componente.
12. Un investigador plantea la hipótesis de que el gusano blanco de la papa se puede controlar biológicamente usando tres especies de nematodos. Para su aplicación, quiere ensayar tres sistemas diferentes: en la superficie, en la parte media y en el fondo de cada materia formando un círculo. La efectividad del sistema puede variar de acuerdo con el nematodo. Para evitar complejidad, el investigador esterilizará el suelo y, posteriormente, aplicará soluciones nutritivas a todas las materias e infestará cada materia con igual número de larvas. La infestación con las larvas la hace 8 días después de la floración del cultivo de papa y la aplicación de los nematodos 15 días antes de la infestación. Se consideró la materia con 2 kg de suelo y una planta como unidad experimental. Por tratamiento se tienen 10 unidades experimentales en un invernadero.
- a. ¿Qué diseño experimental recomendaría? Justifique su respuesta.
 - b. ¿Cómo asignaría los tratamientos a las unidades experimentales?
 - c. ¿Qué variable(s) mediría?
 - d. Escriba una tabla de análisis mostrando solamente las fuentes de variación y los grados de libertad.

- e. ¿Son los factores cualitativos o cuantitativos?
- f. Considere los factores aleatorios y escriba cómo calcular las componentes de varianza y las pruebas de F que sean de interés.
13. Para determinar la permanencia del controlador biológico *beauveria bassiana* sobre las hojas del cafeto después de un aguacero, se piensa hacer un experimento en el cual se usará un solo simulador de lluvia para despachar una misma cantidad de agua con diferentes tiempos de duración para una intensidad dada. Los tiempos de duración son: 30, 60 y 90 minutos en horas de la tarde. Se asperjan 3 dosis del hongo (10^8 , 10^{10} y 10^{12} esporas por mililitro) debidamente calibradas, con lo que se espera tener una distribución uniforme del número de gotas por centímetro cuadrado en las hojas. La unidad experimental está constituida por 10 plántulas de 6 meses de edad. Se quiere medir el número de esporas promedio en 5 campos de la hoja. El simulador de lluvia logra regar 30 plantas a la vez. El investigador cuenta con 450 plantas para su experimento. ¿Qué diseño experimental recomienda? ¿Qué le recomendaría al investigador para hacer el análisis de los datos? Justifique su respuesta
14. Escriba una tabla de análisis de varianza acorde con el siguiente modelo:
- $$y_{ijk} = \mu + \alpha_i + \delta_{k(i)} + \beta_j + (\alpha\beta)_{ij} + \epsilon_{ijk},$$
- con $i = 1, 2, 3, j = 1, 2, k = 1, 2, 3, 4$. ¿Qué clase de modelo es?
15. Un químico se enfrenta al problema de dónde debe concentrar los esfuerzos para el siguiente ensayo: se aplica una serie de 8 tratamientos en DBCA con 2 reproducciones; se toman en el campo 3 muestras de cada parcela, cada muestra se divide en dos porciones en el laboratorio y se duplican las determinaciones para cada porción que debe ser analizada. La información se resume en la siguiente tabla:

C de V	gl	CM	
$T : \mu$	11700		T: Tratamientos
$TP : \mu$	1300		P: Parcelas
$M : TP\mu$	100		M: Muestras
$S : MTP\mu$	20		S: Porciones
$D : STMP\mu$	16		D: Determinaciones

Obtenga $E(CM)$ y estime las componentes de varianza.

16. A continuación se analizan los datos de un experimento en caña de azúcar. En las parcelas grandes se ensayaron dos tratamientos: con compuesto orgánico (C) y sin compuesto orgánico (S). En las subparcelas se ensayaron cuatro tratamientos: testigo, Cal 1.5 Ton/ha., Cal 3.0 Ton/ha. y Cal 4.5 Ton/ha.

La respuesta de interés fue el rendimiento del campo en kilogramos por parcela chica de 100.8 m^2 , y se generó la variable R ($R = Y/(100.85)$) para el rendimiento de caña en toneladas por hectárea, como se muestra en el siguiente programa de SAS.

```
DATA EJERCICIO;
INPUT REP CAMP $ CAL Y @@;
R= Y/100.8;
C= 1.5* (CAL - 1);
CARDS;
1 C 3 960
1 C 2 898
1 C 1 920
1 C 4 877
1 S 2 690
1 S 4 1055
1 S 1 767
1 S 3 857
2 C 1 989
2 C 4 1020
2 C 2 948
2 C 3 848
2 S 3 721
2 S 2 889
2 S 4 994
2 S 1 764
3 S 4 701
3 S 1 741
3 S 3 931
3 S 1 833
3 C 4 811
3 C 3 993
3 C 1 901
3 C 2 1058
4 S 2 574
4 S 3 758
4 S 1 584
4 S 4 994
4 C 1 817
4 C 4 771
4 C 3 918
```

```
4 C 2 874
;
```

```
PROC GLM DATA=EJERCICIO;
CLASS REP CAMP CAL;
MODEL R= REP CAMP REP*CAMP CAL CAL*CAMP;
MEANS CAL CAMP CAL*CAMP;
TEST H= REP CAMP E= REP*CAMP;
```

```
PROC GLM;
MODEL R=C;
RUN;
```

Corra el programa e interprete los resultados arrojados en cada una de las diferentes salidas.

The background of the slide is a repeating pattern of 3D surface plots. Each plot shows a curved surface over a square domain. The horizontal axes are labeled 'temperatura' and 'tiempo', with numerical values ranging from 125 to 150. The vertical axis has values from 88 to 96. The surface is represented by a grid of lines, and its projection on the base plane shows concentric contour lines.

Capítulo *doce* **Metodología de superficies de respuesta**

12.1. Introducción

La metodología de superficies de respuesta (MSR) tuvo sus desarrollos en el área de la ingeniería química e industrial, particularmente cuando se tienen en cuenta varias variables que influyen en un proceso de producción. Este método es una colección de técnicas de diseño experimental, métodos de regresión y optimización de procesos. También son importantes en el diseño, desarrollo y formulación de nuevos productos así como para mejorar los productos existentes. Se resaltan las investigaciones en ciencias de la salud, industria, agricultura, biología, economía, entre otras, en que se presentan situaciones en las que los procesos se centran en el análisis de los datos registrados sobre un conjunto de individuos al que se le aplica un tratamiento, por lo que se hace necesario determinar las condiciones bajo las cuales los resultados son los mejores en términos de calidad y/o costos. Cada tratamiento resulta de la combinación de niveles de los factores de investigación, el objetivo es encontrar la combinación de estos niveles que optimice las variables respuesta del proceso.

El primer trabajo publicado en el área fue el de Box y Wilson (1951), quienes trabajaron sobre una región experimental cambiante, según las condiciones del experimento. Box (1952) propone una alternativa en los diseños factoriales de primer orden para la optimización. Posteriormente, Box (1954) y Box y Hunter (1957) direccionan sus estudios sobre diseños ortogonales rotatables de primer y segundo orden, en los que el sesgo en términos de orden superior no es importante. Gardiner, Grandage y Hader (1959) presentaron los diseños rotables de tercer orden sin considerar la ortogonalidad; de igual manera, Derringer (1969) discutió procedimientos sobre diseños de tercer orden. Harrington (1965), Derringer y Suich (1980) y Khuri y Colon (1981) trabajan esta metodología pero se enfocan, en particular, en optimización multirespuesta.

Vining y Myers (1990) presentaron los problemas que se tienen en diseños de parámetros robustos como una optimización restringida. Trabajaron los factores de control replicados y propusieron ajustar separadamente el modelo para la respuesta y el proceso de la varianza observada por el mecanismo de replicación, utilizando la optimización de respuesta dual planteada por Myers y Carter (1973). Por otra parte, Vining (1998) retomó el trabajo de Khuri y Colon (1981) al proponer una función que incorpora la matriz de varianzas y covarianzas de las respuestas predichas e introducir un término que penaliza regiones en que la calidad de la predicción es relativamente pobre. Una seria desventaja de este enfoque está en la escogencia de una matriz de costos, la cual constituye un componente subjetivo que refleja la

calidad de conocimiento del proceso. Tang y Xu (2002) generalizaron varias de las metodologías propuestas mediante programación por metas. Este enfoque considera restricciones sobre las variables independientes tanto de tipo esférico como cuboidal. Como casos particulares pueden considerarse los trabajos de Del Castillo y Montgomery (1993) y Lin y Tu (1995). Su desventaja está en no hacer consideraciones sobre la matriz de varianzas y covarianzas de las respuestas y en la calidad de las predicciones como método de optimización.

En la MSR, según Myers y Montgomery (1995) y Khuri y Cornell (1987), se considera una variable respuesta cuantitativa (y), la cual depende de una serie de variables independientes cuantitativas x_i , $i = 1, \dots, k$ y parámetros desconocidos θ_m ($m = 1, \dots, l$). Se plantea la relación

$$y = \eta(x_1, \dots, x_k; \theta_1, \dots, \theta_l).$$

En la práctica, el experimentador está interesado en la relación de la variable respuesta y con un conjunto de variables observadas de la forma

$$y = f(\xi_1, \xi_2, \dots, \xi_k) + e, \quad (12.1)$$

donde $\xi_1, \xi_2, \dots, \xi_k$ son llamadas las *variables naturales*, en razón de que estas son expresadas en las unidades naturales de medida, además se asume que $e \sim N(0, \sigma^2)$.

De esta forma,

$$\begin{aligned} E(y) &= E(f(\xi_1, \xi_2, \dots, \xi_k)) + E(e) \\ \eta &= f(\xi_1, \xi_2, \dots, \xi_k). \end{aligned}$$

En muchas situaciones prácticas en las que se aborda el problema de optimización vía superficies de respuesta, es conveniente transformar las variables naturales (en la escala de medición original) por *variables codificadas* $x_1, x_2, \dots, x_k$. Estas nuevas variables codificadas son usualmente definidas con media cero y la misma desviación estándar. En términos de las variables codificadas, la verdadera función de respuesta es $\eta = f(x_1, x_2, \dots, x_k)$. Usualmente, la función η es desconocida pero no sus parámetros o conocida pero muy complicada para el manejo analítico.

Se busca en estos estudios que la función η se pueda aproximar satisfactoriamente con modelos sencillos en las regiones experimentales de interés. Se destacan en estas metodologías los modelos de primero y segundo orden.

Un modelo de *primer orden* está dado por el hiperplano

$$\eta = \beta_0 + \sum_{i=1}^k \beta_i x_i. \quad (12.2)$$

En particular, por ejemplo, para el modelo $\eta = 50 + 8x_1 + 3x_2$ de efectos principales, la superficie de respuesta y la gráfica de contornos se muestra en la figura 12.1.




Figura 12.1: Superficie de respuesta y gráfico de contorno para el modelo de primer orden $\eta = 50 + 8x_1 + 3x_2$.

La gráfica de la superficie de respuesta y su contorno son importantes en la fase inicial del proceso, puesto que se podría evaluar si el modelo ajustado es adecuado. En los modelos de primer orden, los dos tipos de gráficos no deben presentar indicios de una curvatura. El tipo de modelo planteado en (12.2) recibe el nombre de *modelo de los efectos principales*.

Un modelo de *primer orden con interacción* se puede expresar como

$$\eta = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \sum_{\substack{j=1 \\ i < j}}^k \beta_{ij} x_i x_j. \quad (12.3)$$

Para ilustrar este caso, se presenta el modelo $\eta = 50 + 8x_1 + 3x_2 - 4x_1x_2$ de efectos principales con interacción. La superficie de respuesta y la gráfica de contornos se muestran en la figura 12.2.




Figura 12.2: Superficie de respuesta y gráfico de contorno para el modelo de primer orden con interacción $\eta = 50 + 8x_1 + 3x_2 - 4x_1x_2$.

Se observa que el modelo de primer orden, en que la interacción está incluida, sería inadecuado, puesto que la superficie de respuesta y el gráfico de contornos presentan curvatura. Cuando esto sucede se recomienda ajustar un modelo de *segundo orden* descrito como

$$\eta = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i=1}^k \sum_{\substack{j=1 \\ i < j}}^k \beta_{ij} x_i x_j.$$

Según la naturaleza de la investigación, en ocasiones se recurre a modelos de orden superior. La aproximación de estos modelos está basada en series de expansión de Taylor para una función f alrededor de un punto O de interés.

La base de la metodología de superficies de respuesta (MSR) es encontrar el nivel o niveles óptimos de un factor o factores sobre una respuesta. En general, se hacen pocos experimentos y se enfoca la atención sobre aquellos niveles en que la respuesta de interés es óptima, lo que implica una experimentación secuencial.

Los supuestos básicos que se hacen sobre la MSR son:

1. Existe una estructura de η que es muy complicada o desconocida. Las variables de estudio, por lo general, son continuas, aunque esto no debe ser una restricción en el uso.
2. La función f puede ser aproximada en la región de interés por un polinomio de orden bajo, generalmente lineal o cuadrático.
3. Las variables $x_1, x_2, \dots, x_k$ son controladas en el proceso de observación y medidas con cierto error.

Los objetivos que se persiguen al ajustar una superficie de respuesta son:

- i. Encontrar en una región de interés una aproximación funcional que permita hacer predicciones.
- ii. Determinar los valores de las variables independientes que permitan optimizar la respuesta requerida en un proceso.
- iii. Caracterizar η en alguna región limitada o de intervalo. Por ejemplo, las ecuaciones más usadas con dos variables independientes son:
 - a. Polinomio de segundo grado

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{11} x_1^2 + \beta_{22} x_2^2 + \beta_{12} x_1 x_2.$$

b. Polinomio raíz cuadrada

$$y = \beta_0 + \beta_1\sqrt{x_1} + \beta_2\sqrt{x_2} + \beta_{11}x_1 + \beta_{22}x_2 + \beta_{12}\sqrt{x_1x_2}.$$

c. Una función de Baule que es una generalización de la ley de Mitscherlich

$$y = A[1 - 10^{-c_1(x_1+b_1)}][1 - 10^{-c_2(x_2+b_2)}].$$

d. La función Cobb-Douglas generalizada

$$y = ax_1^{b_1}x_2^{b_2}.$$

En la MSR es frecuente que se haga experimentación secuencial en la localización de puntos de operación óptimos. Usualmente, se inicia con un diseño de primer orden y en la cercanía del óptimo se usa un diseño de segundo orden, rara vez se utiliza un diseño de tercer orden; esto es por considerar que el óptimo será un máximo o un mínimo absoluto.

Cuando se tiene una sola variable en consideración, se recurre a una función de segundo orden y se puede ilustrar en dos dimensiones de tal manera que facilite la obtención de su punto máximo o mínimo.

Si $k = 2$ y se desea caracterizar una función de respuesta de segundo orden por medio de una gráfica, se debe hacer uso de las gráficas de contornos para respuestas constantes o curvas de nivel de contornos. Cuando $k \geq 2$, la función de respuestas es caracterizada por superficies constantes.

Como en la MSR es necesario involucrar dos o más variables independientes a través de un modelo de regresión para lograr una descripción adecuada del proceso bajo estudio o producir inferencias suficientemente precisas, se desarrolla a continuación una breve presentación de estos modelos.

12.2. Modelo de regresión lineal múltiple

Cuando se supone que todas las variables independientes (variables regresoras) están relacionadas con la variable dependiente en forma lineal (respecto a los parámetros) y se comportan en forma independiente unas con respecto a las otras, se tiene un procedimiento llamado *análisis de regresión lineal múltiple* (Draper y Smith 1998).

Así, si se supone que en un estudio se tienen l variables independientes $x_1, x_2, \dots, x_l$, el modelo de regresión lineal se expresa como

$$y_i = \beta_0 + \sum_{j=1}^l \beta_j x_{ij} + e_i, \quad (12.4)$$

con $i = 1, \dots, n$, y_i la respuesta asociada al i -ésimo individuo, x_{ij} hace referencia a la influencia del nivel del factor j -ésimo en el i -ésimo individuo, β_0 y β_j ($j = 1, \dots, l$) son los parámetros (conocidos como coeficientes de regresión) y e_i es el efecto aleatorio asociado a y_i , el cual se asume independiente e idénticamente distribuido $N(0, \sigma^2)$.

El modelo (12.4) se expresa en forma matricial como

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}, \quad (12.5)$$

donde

$$\mathbf{Y}_{n \times 1} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad \mathbf{X}_{n \times (l+1)} = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1l} \\ 1 & x_{21} & x_{22} & \cdots & x_{2l} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nl} \end{pmatrix}$$

$$\boldsymbol{\beta}_{(l+1) \times 1} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_l \end{pmatrix} \quad y \quad \mathbf{e}_{n \times 1} = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{pmatrix}.$$

Usando el método de mínimos cuadrados (o máximo verosimilitud), se obtienen los estimadores de los parámetros $b_0, b_1, \dots, b_l$, minimizando la siguiente ecuación:

$$L = \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^l \beta_j x_{ij} \right)^2. \quad (12.6)$$

Los parámetros estimados $b_0, b_1, \dots, b_l$ que minimizan la expresión (12.6) son soluciones de las $(l+1)$ ecuaciones normales

$$\begin{aligned} nb_0 + b_1 \sum_{i=1}^n x_{i1} + \cdots + b_l \sum_{i=1}^n x_{il} &= \sum_{i=1}^n y_i \\ b_0 \sum_{i=1}^n x_{i1} + b_1 \sum_{i=1}^n x_{i1}^2 + \cdots + b_k \sum_{i=1}^n x_{i1} x_{il} &= \sum_{i=1}^n x_{i1} y_i \\ &\vdots \\ b_0 \sum_{i=1}^n x_{il} + b_1 \sum_{i=1}^n x_{il} x_{i1} + \cdots + b_k \sum_{i=1}^n x_{il}^2 &= \sum_{i=1}^n x_{il} y_i \end{aligned}$$

o, en forma matricial,

$$\mathbf{X}^t \mathbf{X} \mathbf{b} = \mathbf{X}^t \mathbf{Y}. \quad (12.7)$$

Al solucionar el sistema de ecuaciones normales (12.7), se llega a la solución

$$\mathbf{b} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y} = \begin{pmatrix} b_0 \\ b_1 \\ \vdots \\ b_l \end{pmatrix}.$$

Estos coeficientes satisfacen las siguientes propiedades:

- i. $E(\mathbf{b}) = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t E(\mathbf{Y}) = \boldsymbol{\beta}$.
- ii. $Var(\mathbf{b}) = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t Var(\mathbf{Y}) \mathbf{X} (\mathbf{X}^t \mathbf{X})^{-1} = (\mathbf{X}^t \mathbf{X})^{-1} \sigma^2$.

Si $\mathbf{C} = (\mathbf{X}^t \mathbf{X})^{-1}$, entonces la varianza del j -ésimo elemento, es decir, $Var(b_j) = c_{jj} \sigma^2$, $j = 1, \dots, l$. En tanto que $cov(b_j, b_{j'}) = c_{jj'} \sigma^2$ y, además, por la normalidad, se satisface que

$$\mathbf{b} \sim N(\boldsymbol{\beta}, (\mathbf{X}^t \mathbf{X})^{-1} \sigma^2).$$

Con base en el anterior resultado, se pueden realizar pruebas de hipótesis y estimación por intervalo sobre los parámetros $\boldsymbol{\beta}$.

12.2.1. Predicción de la variable respuesta y estudios de residuales

Uno de los propósitos al ajustar un modelo es usar el mismo para predecir una respuesta a lo largo de una región experimental. Así, si $\mathbf{x}_p^t$ es un vector $1 \times p$, cuyos elementos corresponden a una fila de la matriz $\mathbf{X}$, el valor de predicción de la respuesta y_p en el punto $\mathbf{x}_p$ es:

$$\hat{y}_p = \mathbf{x}_p^t \mathbf{b}.$$

La dispersión de la predicción $\hat{y}_p$, definido como la varianza de $\hat{y}_p$, es:

$$Var(\hat{y}_p) = \mathbf{x}_p^t (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{x}_p \sigma^2,$$

y el error estándar de la predicción es $\sqrt{\mathbf{x}_p^t (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{x}_p \sigma^2}$.

El error estándar se utiliza para construir los límites alrededor de la respuesta predicha, es decir, a partir de este se puede recomendar una mejor aproximación a la región óptima. El error estándar puede ser calculado en algún punto en que el investigador considere que es la ubicación potencial de la región de diseño.

Un intervalo de confianza para $\hat{y}_p$ está dado por

$$\hat{y}_p \pm t_{\alpha/2} s \sqrt{\mathbf{x}_p^t (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{x}_p},$$

con $s = \sqrt{\frac{\sum_{i=1}^k (y_i - \hat{y}_i)^2}{n-l-1}} = \left(\frac{\mathbf{Y}^t [\mathbf{I} - \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t] \mathbf{Y}}{n-l-1} \right)^{\frac{1}{2}}$, el cual es un estimador insesgado de σ^2 .

El intervalo de confianza orienta los cálculos sobre la respuesta para los valores que se están ubicando en la región de diseño, llevando al investigador a conclusiones razonables para hacer recomendaciones sobre el experimento.

Sea $\hat{\mathbf{Y}}$ el vector de valores predichos $\hat{y}_i$, los cuales se representan mediante

$$\hat{\mathbf{Y}} = \mathbf{X}\mathbf{b} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y} = \mathbf{P}\mathbf{Y} = \begin{pmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_n \end{pmatrix},$$

donde $\mathbf{P} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t$ es la matriz de proyección. Adicionalmente, $\hat{\mathbf{e}}$ es el vector de residuales $\hat{e}_i = y_i - \hat{y}_i$ ($i = 1, \dots, n$), el cual se puede expresar matricialmente como

$$\hat{\mathbf{e}} = \mathbf{Y} - \hat{\mathbf{Y}} = (\mathbf{I} - \mathbf{P})\mathbf{Y} = \begin{pmatrix} \hat{e}_1 \\ \hat{e}_2 \\ \vdots \\ \hat{e}_n \end{pmatrix}.$$

Finalmente, la estimación de σ^2 es:

$$\hat{\sigma}^2 = \frac{1}{n - (l + 1)} \sum_{i=1}^n \hat{e}_i^2 = \frac{1}{n - (l + 1)} (\mathbf{Y} - \mathbf{X}\mathbf{b})^t (\mathbf{Y} - \mathbf{X}\mathbf{b})$$

12.2.2. Resultados para el análisis de varianza

A continuación se presentan las diferentes sumas de cuadrados con la finalidad de construir la tabla de análisis de varianza y los estadísticos de prueba tendientes a evaluar si existe relación entre la variable dependiente y y el conjunto de variables $x_1, \dots, x_l$, es decir, se formula la hipótesis

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_l = 0.$$

Entonces, la suma de cuadrados total se puede particionar como $SCT = SCR + SCE$ o, equivalentemente

$$\begin{aligned} Y^t \left(I - \frac{1}{n} (\mathbf{1}\mathbf{1}^t) \right) Y &= \left(b^t X^t Y - \frac{1}{n} Y^t (\mathbf{1}\mathbf{1}^t) Y \right) + (Y^t Y - b^t X^t Y) \\ Y^t \left(I - \frac{1}{n} J \right) Y &= Y^t \left(P - \frac{1}{n} J \right) Y + Y^t (I - P) Y \\ \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2. \end{aligned}$$

En forma de sumatoria

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$

J una matriz de unos de orden $n \times n$ y las sumas de cuadrados total del error y de la regresión (SCT_{CM} , SCE y SCR) tienen asociados $n - 1$, $n - (l + 1)$ y l grados de libertad, respectivamente.

En la tabla 12.1, se presentan los resultados del análisis de varianza, lo mismo que los cuadrados medios de la regresión (CMR) y del error (CME).

Tabla 12.1: Análisis de varianza para el modelo de regresión (12.4)

C. de V.	gl	SC	CM
Regresión	l	$b^t X^t Y - \frac{1}{n} Y^t J Y$	$\frac{SCR}{l}$
Error	$n - (l + 1)$	$Y^t Y - b^t X^t Y$	$\frac{SCE}{n-l-1}$
Total	$n - 1$	$Y^t Y - \frac{1}{n} Y^t J Y$	

El valor esperado de CME es σ^2 , en tanto que el valor esperado de CMR es σ^2 más una cantidad no negativa; por ejemplo, si $l = 2$, se tiene

$$\begin{aligned} E(CMR) &= \sigma^2 + \frac{1}{2} [\beta_1^2 \sum_{i=1}^n (x_{i1} - \bar{x}_{.1})^2 + \beta_2^2 \sum_{i=1}^n (x_{i2} - \bar{x}_{.2})^2 \\ &\quad + 2\beta_1\beta_2 \sum_{i=1}^n (x_{i1} - \bar{x}_{.1})(x_{i2} - \bar{x}_{.2})]. \end{aligned}$$

Es de notar que si β_1 y β_2 son iguales a cero (bajo la hipótesis nula cierta), entonces $E(CMR) = \sigma^2$, de otra forma $E(CMR) > \sigma^2$.

Al asumir normalidad en los errores, para la prueba H_0 se utiliza el estadístico de prueba

$$F = \frac{CMR}{CME} \sim F_{(l, n-l-1)}.$$

Si este valor es mayor que una $F_{(l, n-l-1, \alpha)}$, se rechaza H_0 .

Observación 12.1. La existencia de una relación funcional mediante un modelo de regresión por sí misma no asegura que se puedan hacer predicciones útiles a partir de ella.

Es conveniente que el estadístico F esté acompañado del coeficiente de determinación múltiple encontrado como:

$$R^2 = \frac{SCR}{SCT} = 1 - \frac{SCE}{SCT}.$$

Este valor mide la proporción de la variación total de los valores de y_i alrededor de la media $\bar{y}$ explicada por el ajuste del modelo.

El coeficiente de determinación presenta gran debilidad en el momento de ser usado para comparar la bondad de ajuste de dos o más modelos, en particular, cuando uno de los modelos posee todas la variables independientes del otro más alguna variable adicional, pues el R^2 crece a medida que se introducen nuevas variables predictoras en el modelo, no importando si la variable aporta nueva información en la explicación de la variable respuesta y_i .

Por estas razones, algunos autores recomiendan trabajar con el R^2 ajustado definido como

$$R^2_{ajus} = 1 - \frac{CME}{CMT} = 1 - \frac{(n-1)SCE}{(n-l-1)SCT} = 1 - \frac{n-1}{n-l-1}(1-R^2).$$

Este coeficiente penaliza la entrada de nuevas variables en el modelo.

12.2.3. Pruebas de hipótesis asociadas a los parámetros individuales en el modelo

Para ver el efecto de los parámetros individuales en el ajuste del modelo se plantea la hipótesis $H_0 : \beta_j = 0, j = 1, \dots, l$, la cual se verifica a través del estadístico de prueba

$$t = \frac{b_j}{\sqrt{c_{jj}CME}},$$

el cual se compara con el valor tabulado $t_{(n-l-1, \alpha/2)}$. Si este valor es menor al calculado, entonces se rechaza la hipótesis $H_0 : \beta_j = 0$. Adicionalmente, un intervalo de confianza para β_j del tamaño $(1 - \alpha) \%$ está dado por

$$b_j \mp t_{(n-l-1, \alpha/2)} \sqrt{c_{jj}CME}.$$

Cuando el modelo contiene más de un parámetro desconocido y la estimación de los coeficientes de los términos $\beta_j x_j$ y $\beta_{j'} x_{j'}$ en el modelo está

correlacionada (es decir, $c_{jj'}\sigma^2 \neq 0$), entonces las pruebas para las hipótesis $H_0 : \beta_j = 0$ y $H_0 : \beta_{j'} = 0$ no son independientes.

En consecuencia, cuando la hipótesis nula es de la forma $H_0 : \beta_j = 0$, significa que $\beta_j x_j$ no explica alguna cantidad adicional de variación en la respuesta, esta es explicada por otros términos en el modelo. Así por ejemplo, $H_0 : \beta_{12} = 0$ coeficiente asociado al término $\beta_{12} x_1 x_2$ es una prueba de equivalencia entre los siguientes dos modelos:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{22} x_2^2 + e$$

y, bajo la hipótesis alternativa,

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{22} x_2^2 + \beta_{12} x_1 x_2 + e$$

Esta introducción de términos nuevos al modelo se conoce como una prueba parcial F para β_{12} .

Ejemplo 12.1. *Khuri y Cornell (1987) citan un experimento en el cual se tomaron 12 ratones de igual tamaño y edad, a los cuales se les suprimía el alimento excepto durante una hora por día durante 10 días. En el día 11, cada ratón fue inoculado con una droga que disminuía el hambre (en dosis de 0.3 y 0.7 mg/kg) después de un tiempo específico (tiempos 1, 5 y 9 horas). Cada combinación dosis $\times$ tiempo se les aplicó a dos ratones. El peso, en gramos, de la comida ingerida por cada ratón fue medido. El propósito del experimento fue determinar si el cambio en los niveles de las dosis de la droga y la longitud del tiempo entre la inoculación tiene algún efecto en los ratones en términos de la cantidad de alimento consumido.*

Los datos obtenidos se presentan en la tabla 12.2.

Tabla 12.2: Peso por alimento consumido en ratones para los datos de Khuri y Cornell

Dosis droga (mg/kg)	Tiempo						Total
	1		5		9		
0.3	5.63	6.42	11.57	12.16	12.68	13.31	61.77
0.7	1.38	1.94	5.72	4.69	8.28	7.73	29.74
Total	15.37		34.14		42.00		91.51

El modelo propuesto para esta ensayo es:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_{12} x_{i1} x_{i2} + \beta_{22} x_{i2}^2 + e_i, \quad i = 1, \dots, 12. \quad (12.8)$$

En la figura 12.3, se ilustran los pesos promedio, con la finalidad de determinar la posible interacción entre tiempo y dosis de la droga. En esta figura no se encuentran indicios de esta interacción, por consiguiente, es posible que en el modelo (12.8) la

misma (medida a través de β_{12}) no sea significativa. Para tal fin, a continuación se realizará el proceso de estimación de los parámetros involucrados en el modelo vía análisis de varianza.




Figura 12.3: Interacción entre el tiempo y la dosis de la droga según el peso por alimento consumido por los ratones.

En forma matricial, el modelo (12.8) se puede expresar como:

$$\begin{pmatrix} 5.63 \\ 6.42 \\ 1.38 \\ 1.94 \\ 11.57 \\ 12.16 \\ 5.72 \\ 4.69 \\ 12.68 \\ 13.31 \\ 8.28 \\ 7.73 \end{pmatrix} = \begin{pmatrix} 1 & 0.3 & 1 & 0.3 & 1 \\ 1 & 0.3 & 1 & 0.3 & 1 \\ 1 & 0.7 & 1 & 0.7 & 1 \\ 1 & 0.7 & 1 & 0.7 & 1 \\ 1 & 0.3 & 5 & 1.5 & 25 \\ 1 & 0.3 & 5 & 1.5 & 25 \\ 1 & 0.7 & 5 & 3.5 & 25 \\ 1 & 0.7 & 5 & 3.5 & 25 \\ 1 & 0.3 & 9 & 2.7 & 81 \\ 1 & 0.3 & 9 & 2.7 & 81 \\ 1 & 0.7 & 9 & 6.3 & 81 \\ 1 & 0.7 & 9 & 6.3 & 81 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_{12} \\ \beta_{22} \end{pmatrix} + e$$

Al emplear mínimos cuadrados, se obtienen los estimadores de los diferentes parámetros involucrados en el modelo (12.8). En la tabla 12.3, se presentan los coeficientes estimados junto con las desviaciones estándar y sus estadísticos de prueba.

Tabla 12.3: Coeficientes estimados al ajustar el modelo (12.8)

Efecto	gl	Coeficiente	Desv. coef.	t	Valor p
Constante	1	8.43	1.17	7.19	0.00
Dosis	1	-12.37	2.03	-6.09	0.00
Tiempo	1	1.78	0.35	5.14	0.00
Dosis*Tiempo	1	-0.19	0.34	-0.57	0.58
Tiempo*Tiempo	1	-0.09	0.03	-2.89	0.02

A partir de los resultados de la tabla de análisis de varianza 12.4, la razón F para juzgar la hipótesis $H_0 : \beta_1 = \beta_2 = \beta_{12} = \beta_{22} = 0$ es:

$$F = \frac{44.82}{4.14} = 75.73.$$

Este valor de la F conlleva a la no aceptación de la hipótesis nula (valor $p \cong 0.00$), con lo cual se concluye que esta hipótesis se rechaza. Adicionalmente, con base en los resultados obtenidos en las tablas, se concluye que la interacción no es un efecto significativo en el modelo, es decir, que la dosis y el tiempo no interactúan conjuntamente sobre la cantidad de alimento consumido por los ratones, lo cual corrobora lo observado en la figura 12.3.

Tabla 12.4: Análisis de varianza para el peso por alimento consumido en los ratones

C. de V.	GL	SC(secue)	SC(ajus)	CM(ajus)	F	Valor P
Regresión	4	179.29	179.29	44.82	75.73	0.00
Lineal	2	174.14	63.52	31.76	53.65	0.00
Cuadrática	1	4.96	4.96	4.96	8.38	0.02
Interacción	1	0.20	0.20	0.20	0.33	0.58
Error	7	4.14	4.14	0.59		
Total	11	183.44				

Como $R_{ajus}^2 = 0.96$, se puede concluir entonces que el total de la variación de la cantidad de alimento ingerida por los ratones es explicada en un 96 % por las variables dosis y tiempo. Los valores de predicción y los residuales se presentan en la tabla 12.5.

Como en los diseños experimentales, se ajusta una respuesta a través de un modelo polinomial, en el cual se tienen diferentes valores en la respuesta para los mismos valores en las variables explicativas, por lo que se hace necesario realizar una prueba de falta de ajuste del modelo para determinar si el mismo es apropiado o no para describir los datos. El procedimiento de evaluación de la adecuación del modelo se desarrolla a continuación.

Tabla 12.5: Predicciones y residuales al ajustar el modelo (12.8)

Dosis	Tiempo	Peso obs.	Predicción	Residual
0.3	1	5.63	6.36	-0.73
		6.42	6.36	0.06
0.7	1	1.38	1.33	0.05
		1.94	1.33	0.61
0.3	5	11.57	11.20	0.37
		12.16	11.20	0.96
0.7	5	5.72	5.87	-0.15
		4.69	5.87	-1.18
0.3	9	12.68	13.33	-0.65
		13.31	13.33	-0.02
0.7	9	8.28	7.67	0.61
		7.73	7.67	0.06

12.3. Prueba de falta de ajuste

En la prueba de falta de ajuste del modelo, se puede presentar una de las siguientes causas:

- Se omiten factores del modelo propuesto que afectan la respuesta.
- La omisión de términos de mayor orden involucrando factores en el modelo propuesto, los cuales son necesarios para explicar adecuadamente el comportamiento de la respuesta.

Para detectar si el modelo ajustado es inadecuado, se debe tener en cuenta lo siguiente:

Si la forma apropiada de la superficie puede representarse con los términos adicionales al modelo propuesto $\mathbf{X}_q \boldsymbol{\beta}_q$, entonces la superficie verdadera puede expresarse como

$$E(Y) = \mathbf{X} \boldsymbol{\beta} + \mathbf{X}_q \boldsymbol{\beta}_q, \quad (12.9)$$

donde $\mathbf{X}_q$ es la matriz de términos en $x_1, x_2, \dots, x_l$ de orden mayor a los de $\mathbf{X}$.

Observación 12.2. Alternativamente, $\mathbf{X}_q$ puede tener las variables $x_{l+1}, x_{l+2}, \dots, x_m$ no contenidas en $\mathbf{X}$.

Dados los modelos (12.5) y (12.9) para la superficie de respuesta propuesta y la superficie verdadera, respectivamente, entonces la inhabilidad del modelo ajustado $\hat{Y} = \mathbf{X} \mathbf{b}$ para determinar la adecuada variación en los valores de la respuesta observada está reflejada en la porción de la variación

total llamada varianza residual, dada por el modelo ajustado. Al aislar la varianza residual de aquella atribuida directamente al modelo (12.9) con el modelo ajustado, se hace necesario una prueba de ajuste del modelo.

La prueba para el ajuste del modelo apropiado requiere dos condiciones que dependen de la naturaleza de los datos:

1. El número de puntos distantes del diseño n puede exceder el número de términos en el modelo ajustado. Si el modelo ajustado contiene l términos, entonces $n > l$.
2. Una estimación de la varianza del error experimental no requiere de la forma del modelo ajustado. Esta puede ser obtenida cuando se hacen al menos dos réplicas por tratamiento y puede ser obtenida calculando la variación entre las replicaciones para cada tratamiento.

Cuando lo anterior sucede, la SCE se particiona en dos fuentes de variación:

- i. La variación dentro de replicaciones para aquellos puntos del diseño donde se ha tomado información.
- ii. La variación debida a la falta de ajuste del modelo.

A la suma de cuadrados de las observaciones replicadas se le llama *suma de cuadrados del error puro* ($SCEP$) y la diferencia entre $SCE - SCEP = SCFA$ es la *suma de cuadrados de la falta de ajuste*.

Para una mejor ilustración, se supone que se tiene un total de n observaciones de la variable respuesta Y , tales que

$$\begin{array}{ll} y_{11}, y_{12}, \dots, y_{1n_1}, & \text{con } n_1 \text{ observaciones en el punto 1 del diseño.} \\ y_{21}, y_{22}, \dots, y_{2n_2}, & \text{con } n_2 \text{ observaciones en el punto 2 del diseño.} \\ \vdots & \vdots \\ y_{m1}, y_{m2}, \dots, y_{mn_m}, & \text{con } n_m \text{ observaciones en el punto } m \text{ del diseño;} \end{array}$$

con $n = \sum_{i=1}^m n_i$ y m el número de grupos diferentes que se pueden formar con los mismos x 's.

La suma de cuadrados del error puro es una parte de la suma de cuadrados del error. Se puede escribir el error para la j -ésima observación en el i -ésimo grupo como

$$y_{ij} - \hat{y}_i = (y_{ij} - \bar{y}_i) - (\hat{y}_i - \bar{y}_i).$$

Utilizando el hecho que todas las observaciones replicadas en el i -ésimo grupo tendrían el mismo valor predicho $\hat{y}_i$, elevando al cuadrado a ambos lados y sumando sobre i y j , se obtiene

$$\begin{array}{ccccc}
\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \hat{y}_i)^2 & = & \sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i.})^2 & + & \sum_{i=1}^m \sum_{j=1}^{n_i} (\hat{y}_i - \bar{y}_{i.})^2. \\
\Downarrow & & \Downarrow & & \Downarrow \\
\text{Suma de cuadrados} & & \text{Suma de cuadrados} & & \text{Suma de cuadrados} \\
\text{del error} & & \text{del error puro} & & \text{de la falta de ajuste}
\end{array}$$

La igualdad se mantiene porque la suma del producto cruzado $\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i.})(\hat{y}_i - \bar{y}_{i.})$ es cero.

Los grados de libertad de cada una de las sumas de cuadrados anteriores son, respectivamente,

$$n - l - 1, \quad \sum_{i=1}^m (n_i - 1) = \sum_{i=1}^m n_i - m = n - m \quad \text{y} \quad m - l - 1.$$

Con estos resultados, se tiene que el cuadrado medio del error puro es:

$$CMEP = \frac{\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i.})^2}{n - m},$$

el cual es un estimador de σ^2 indistintamente de si el modelo que está siendo ajustado es correcto o no.

Con esta descomposición del error, se procede a construir la tabla 12.6 de análisis de varianza.

Tabla 12.6: Análisis de varianza para la falta de ajuste en el modelo de regresión (12.5).

C. de V.	gl	SC	CM
Regresión	l	$\sum_{i=1}^m n_i (\bar{y}_i - \bar{y}_{..})^2$	CMR
Error	$n - (l + 1)$	$\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \hat{y}_i)^2$	CME
Falta de ajuste	$m - l - 1$	$\sum_{i=1}^m n_i (\hat{y}_i - \bar{y}_{i.})^2$	$CMEFA$
Error puro	$n - m$	$\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i.})^2$	$CMEP$
Total	$n - 1$	$\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{..})^2$	

En este caso, se plantea la hipótesis H_0 : el modelo ajusta los datos ($E(y_i) = x_i^t \beta$) y se debe asumir que esta es cierta. Como

$$\begin{aligned}
(1) \quad E(CMEP) &= \sigma^2 \\
(2) \quad E(CMEFA) &= \sigma^2 + \frac{\sum_{i=1}^m n_i (E(y_i) - x_i^t \beta)^2}{m - l - 1},
\end{aligned}$$

entonces, bajo H_0 , se tiene que $E(CMEFA) = \sigma^2$; teniendo así dos estimadores de la varianza residual σ^2 . Por lo tanto, el estadístico de prueba es:

$$F = \frac{CMEFA}{CMEP} \sim F_{(m-l-1, n-m)} \text{ bajo } H_0.$$

Si el valor de la estadística es cercano a uno, no se tendrá evidencia para rechazar la hipótesis nula.

Ejemplo 12.2. Para ilustrar el uso de la prueba de falta de ajuste del modelo de segundo orden, se tienen en cuenta los datos de la cantidad de alimento consumido por los ratones, presentados en el ejemplo 12.1. Se sabe que $SCE = 4.14$ con 7 grados de libertad. Por consiguiente,

$$\begin{aligned} SCEP &= (5.63 - 6.025)^2 + (6.42 - 6.025)^2 + \dots + (8.28 - 8.005)^2 \\ &\quad + (7.73 - 8.005)^2 = 1.52, \end{aligned}$$

con $glEP = 12 - 6 = 6$, y

$$SCEFA = 4.14 - 1.52 = 2.62,$$

con $glEFA = 7 - 6 = 1$. Por lo tanto, el estadístico de prueba es $F = 10.32 > F_{(1,6,0.05)} = 5.98$, concluyendo que hay suficiente evidencia de falta de ajuste en el modelo propuesto. Cuando esto sucede, se debe proponer otro modelo que solucione tal problema con la finalidad de realizar inferencias válidas y con sentido práctico para una experimentación futura.

12.4. Método de la trayectoria en máximo ascenso

El método de la trayectoria en máximo ascenso tiene aplicación cuando se están ajustando modelos de primer orden, que es uno de los pasos iniciales en el trabajo de la metodología de superficie de respuesta, puesto que se busca un modelo que sea simple y económico en cuanto a tiempo y costos.

Con frecuencia, la estimación inicial de las condiciones de operación óptimas para un sistema estará alejada del óptimo real. En un experimento se asume que un modelo podría ser una aproximación razonable de un sistema inicialmente en la región de $x_1, x_2, \dots, x_l$, entonces el método de la trayectoria en máximo ascenso permite encontrar la aproximación o el punto máximo. Desde luego, si lo que se pretende es una minimización, entonces esta técnica se llama *método de la trayectoria en máximo descenso*.

El modelo de primer orden (12.2) y la superficie de respuesta de primer orden, es decir, los contornos de $\hat{y}$ constituyen una serie de rectas paralelas como las que se presentaron en la figura 12.1. La dirección de la trayectoria en máximo ascenso es aquella en la que $\hat{y}$ se incrementa con mayor rapidez. Esta dirección es paralela a la normal de la superficie de respuesta ajustada. Por lo general, se toma como la *trayectoria de máximo ascenso* a la recta que pasa por el centro de la región de interés y que es normal a la superficie ajustada.

Para la búsqueda de esta trayectoria se deben tener en cuenta los siguientes pasos:

1. Ajustar un modelo lineal usando un diseño ortogonal. El diseño apropiado es uno de dos niveles aumentado con puntos centrales.
2. Calcular la trayectoria de máximo ascenso, se espera un incremento máximo en dicha respuesta. Habrá un máximo descenso, si la trayectoria produce un máximo decremento en la respuesta.
3. En función del modelo propuesto, conducir el experimento a lo largo de una trayectoria, esto es, hacer una o varias réplicas y observar la respuesta. En este proceso se debe tener presente el momento en que la respuesta deja de incrementarse.
4. Donde se encuentra esa aproximación a la respuesta mínima o máxima, se localiza la trayectoria, y esta es la base para un segundo estudio. Es importante tener en cuenta los puntos centrales para juzgar la curvatura y los grados de libertad para estudiar la falta de ajuste.
5. Se conduce un segundo experimento y se prueba la falta de ajuste. Si el ajuste no es significativo, se tendrá en cuenta una nueva trayectoria teniendo en cuenta el nuevo modelo.

12.4.1. Cálculo de la trayectoria en máximo ascenso

Este cálculo de las coordenadas a lo largo de la trayectoria en máximo ascenso depende de la naturaleza de los coeficientes del modelo de regresión de primer orden. El movimiento en x_i a lo largo de la trayectoria es proporcional a la magnitud de los coeficientes de regresión b_i en la dirección que tomen los signos del coeficiente de regresión. La trayectoria en máximo descenso requiere la dirección opuesta de los signos de los coeficientes.

El procedimiento matemático que permite encontrar esta trayectoria es el siguiente:

Sea

$$\hat{y} = b_0 + b_1x_1 + \cdots + b_lx_l \quad (12.10)$$

un modelo de primer orden ajustado. La trayectoria en máximo ascenso significa obtener una repuesta máxima en límite $\sum_{i=1}^l x_i^2 = r^2$; es decir, todos los puntos se encuentran a una distancia fija r del centro del diseño y se busca el punto $x_1, x_2, \dots, x_l$, el cual maximiza la respuesta. Este procedimiento requiere de los multiplicadores de lagrange, para ello se propone la ecuación

$$L = b_0 + b_1x_1 + \cdots + b_lx_l - \lambda \left(\sum_{i=1}^l x_i^2 - r^2 \right).$$

Derivando con respecto a x_i , se obtiene

$$\frac{\partial L}{\partial x_i} = b_i - 2\lambda x_i; \quad i = 1, \dots, l.$$

Al igualar a cero, se encuentran las coordenadas

$$x_i = \frac{b_i}{2\lambda},$$

en las que la constante $\frac{1}{2}\lambda$ se puede entender como una constante de proporcionalidad dada por $x_1 = \rho$, $x_2 = \rho b_2, \dots, x_l = \rho b_l$.

En la trayectoria en máximo ascenso el signo de ρ es positivo y para la trayectoria en máximo descenso es negativo.

La metodología de la trayectoria en máximo ascenso permite verificar el ajuste del modelo de primer orden, además, busca evidencia de curvatura en el sistema o presencia de interacción entre los factores. En esta etapa, se debe tener en cuenta la adición de los puntos centrales que permite verificar la interacción y hacer un mejor juzgamiento de la curvatura, para ello se debe adicionar los efectos de interacción y analizar si la falta de ajuste es o no significativa. Cada vez que se cambie la trayectoria en máximo ascenso se tendrán en cuenta las últimas aproximaciones dadas por el modelo de trabajo.

Ejemplo 12.3. *Khuri y Cornell (1987) citan un experimento, en un particular proceso de reacción química, en el cual se considera el efecto de las variables: temperatura de reacción (x_1) y longitud de tiempo de la reacción (x_2) sobre el porcentaje de pureza (y), medida en términos de la cantidad del material residual durante la reacción.*

El experimentador está interesado en determinar si es posible tener un incremento en el porcentaje de pureza de un producto, para ello decide realizar un conjunto

de experimentos variando la temperatura y el tiempo de reacción, manteniendo los demás factores fijos. Observó dos niveles de temperatura (70°C y 90°C) y dos niveles de tiempo (30 seg, 90 seg). El proceso opera corrientemente entre un 51 % y un 75 % de pureza, pero se considera que es posible obtener un mayor grado de pureza. Los datos obtenidos se presentan en la tabla 12.7.

Tabla 12.7: Porcentaje de pureza de un producto según la temperatura y el tiempo de reacción

Temperatura °C	Tiempo (seg)	x_1	x_2	% de pureza	
70	30	-1	-1	49.8	48.1
90	30	1	-1	57.3	52.3
70	90	-1	1	65.7	69.4
90	90	1	1	73.1	77.8

Para simplificar los cálculos, las variables independientes se codificaron en el intervalo usual $(-1, 1)$. Por lo tanto, si ξ_1 denota la variable natural temperatura y ξ_2 la variable natural tiempo, entonces las variables codificadas son

$$x_1 = \frac{\xi_1 - 80}{10} \quad y \quad x_2 = \frac{\xi_2 - 60}{30}.$$

Es posible ajustar un modelo de primer orden a estos datos por el procedimiento de mínimos cuadrados. Ajustando los respectivos modelos, se encontró que para las variables originales se ajustó el modelo

$$y = \alpha_0 + \alpha_1 \xi_1 + \alpha_2 \xi_2 + e$$

y para las variables transformadas o codificadas se ajustó el modelo

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + e.$$

Los parámetros de los dos modelos tienen la siguiente equivalencia:

$$\beta_0 = \alpha_0 + 80\alpha_1 + 60\alpha_2, \quad \beta_1 = 10\alpha_1 \quad y \quad \beta_2 = 30\alpha_2.$$

En forma matricial, el modelo con las variables codificadas se puede expresar como

$$\begin{bmatrix} 49.8 \\ 48.1 \\ 57.3 \\ 52.3 \\ 65.7 \\ 69.4 \\ 73.1 \\ 77.8 \end{bmatrix} = \begin{bmatrix} 1 & -1 & -1 \\ 1 & -1 & -1 \\ 1 & 1 & -1 \\ 1 & 1 & -1 \\ 1 & -1 & 1 \\ 1 & -1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_8 \end{bmatrix}.$$

Resolviendo el anterior sistema mediante el método de mínimos cuadrados, se obtiene el modelo ajustado en términos de las variables codificadas

$$\hat{y} = 61.69 + 3.44x_1 + 9.81x_2;$$

en términos de las variables naturales el modelo es

$$\hat{y} = 14.56 + 0.34\xi_1 + 0.33\xi_2.$$

Como la influencia de x_2 sobre el % de pureza es positiva, se observa que la superficie se incrementa más hacia x_2 . Si se desea encontrar un valor de λ para un cambio arbitrario de tiempo (ξ_2), por ejemplo, $\Delta_2 = 45$ segundos en términos de las variables codificadas, se tiene que $x_2 = \frac{45}{30} = 1.5$ y, como $x_i = \frac{b_i}{2\lambda}$, entonces

$$\lambda = \frac{b_2}{2x_2} = \frac{9.81}{2(1.5)} = 3.27.$$

El valor codificado de x_1 correspondiente al cambio de 1.5 unidades en x_2 es:

$$x_1 = \frac{b_1}{2\lambda} = \frac{3.44}{2(3.27)} = 0.53$$

El incremento en la temperatura es $\Delta_1 = (0.53) \times 10 = 5.3$. Luego, el primer punto en la trayectoria ascendente es $(x_1, x_2) = (0.53, 1.5)$, que corresponde en las variables originales a $(\xi_1, \xi_2) = (85.3, 105)$.

El incremento en el % de pureza es

$$\hat{y}(0.53, 1.50) - \hat{y}(0, 0) = 16.54.$$

Adicionalmente, son conducidos otros experimentos a lo largo de la trayectoria ascendente, los resultados se resumen en la tabla 12.8.

Tabla 12.8: Experimentos adicionales para el porcentaje de pureza de un producto según la temperatura y el tiempo de reacción

Pasos	Variables codificadas		Variables naturales		% de pureza
	x_1	x_2	Temp	Tiempo	
Base	0.00	0.00	80.00	60.00	
Δ_i	0.53	1.50	5.30	45.00	
Base+ Δ_i	0.53	1.50	85.30	105.0	74.3
Base+1,5 Δ_i	0.80	2.25	87.95	127.5	78.6
Base+2 Δ_i	1.06	3.00	90.60	150.0	83.2
Base+3 Δ_i	1.59	4.50	95.90	195.0	84.7
Base+4 Δ_i	2.12	6.00	101.20	240.0	80.1

En la figura 12.4, se grafica el % de pureza en cada paso de la trayectoria en máximo ascenso. Se observan incrementos de la respuesta hasta el cuarto paso.

A partir de esta tabla, se observa que hay un decremento en el % de pureza. En este caso no son necesarios experimentos que tengan temperatura encima de 101.2°C y tiempo de 240 seg, sin embargo, teniendo en cuenta este decrecimiento en la producción, se recomienda conducir un segundo grupo de experimentos y nuevamente ajustar un modelo de primer orden teniendo como puntos centrales ($\xi_1 = 95.9^{\circ}\text{C}$, $\xi_2 = 195.0\text{seg}$).




Figura 12.4: % de pureza en los diferentes pasos de la trayectoria de máxima pendiente en ascenso.

La región de exploración en el nuevo estudio debe ser para ξ_1 el intervalo (90.6, 101.2) y para ξ_2 el intervalo (150, 240). Por consiguiente, las variables codificadas con los nuevos puntos centrales son:

$$x_1 = \frac{\text{Temp}(\xi_1) - 95.9}{10} \quad y \quad x_2 = \frac{\text{Tiempo}(\xi_2) - 195}{30}.$$

12.5. Análisis de una superficie de respuesta de segundo orden

Por lo general, debido a la curvatura de la superficie real, el experimentador requiere un modelo cuyo grado sea mayor o igual a dos, el modelo para este tipo de análisis de curvatura es:

$$\hat{y} = b_0 + \sum_{i=1}^k b_i x_i + \sum_{i=1}^k b_{ii} x_i^2 + \sum_{i=1}^k \sum_{\substack{j=1 \\ i < j}}^k b_{ij} x_i x_j \quad (12.11)$$

12.5.1. Localización del punto estacionario

Si se desea determinar los niveles $x_1, x_2, \dots, x_k$ que optimicen la respuesta a partir de puntos estacionarios, se pueden encontrar máximos, mínimos o puntos de silla. La MSR consiste en determinar los niveles de los $x_1, x_2, \dots, x_k$ que maximizan o minimizan la respuesta predicha. Este máximo (o mínimo), si existe, será el conjunto de las derivadas parciales con respecto a x :

$$\frac{\partial \hat{y}}{\partial x_1} = \frac{\partial \hat{y}}{\partial x_2} = \dots = \frac{\partial \hat{y}}{\partial x_k} = 0.$$

Al solucionar el sistema anterior, se obtiene el punto $x_{10}, x_{20}, \dots, x_{k0}$, el cual se denomina punto estacionario y representa un punto de respuesta máximo, mínimo o un punto de silla.

Ejemplo 12.4. *A continuación se ilustran las tres situaciones planteadas anteriormente:*

a. *Punto de respuesta máximo*

$$\hat{\eta} = 80 + 4x_1 + 8x_2 - 4x_1^2 - 12x_2^2 - 12x_1x_2.$$

En la figura 12.5, se presenta el diagrama de contornos y el gráfico de superficies de respuesta asociados con el modelo anterior.




Figura 12.5: Superficie de respuesta y gráfico de contorno para obtener un máximo en el modelo $\hat{\eta} = 80 + 4x_1 + 8x_2 - 4x_1^2 - 12x_2^2 - 12x_1x_2$.

b. *Punto de respuesta mínimo*

$$\hat{\eta} = x_1^2 + x_2^2.$$

En figura 12.6, se presentan los gráficos de contorno y superficies de respuesta asociada con este modelo.




Figura 12.6: Superficie de respuesta y gráfico de contorno para obtener un mínimos en el modelo $\hat{\eta} = x_1^2 + x_2^2$.

c. *Punto de respuesta punto de silla*

$$\hat{\eta} = x_1^2 + 4x_1x_2 - x_2^2 - 5x_1.$$

Los gráficos de contorno y superficie de respuesta asociados con el modelo anterior se presentan en la figura 12.7.




Figura 12.7: Superficie de respuesta y gráfico de contorno para obtener un mínimos en el modelo $\hat{\eta} = x_1^2 + 4x_1x_2 - x_2^2 - 5x_1$.

En este caso, no se puede determinar si hay un máximo o un mínimo.

El modelo de segundo orden de la ecuación (12.11), expresado en forma matricial, corresponde a

$$\hat{y} = b_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\hat{\mathbf{B}}\mathbf{x}, \quad (12.12)$$

donde

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_k \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_k \end{bmatrix}, \quad \hat{\mathbf{B}} = \begin{bmatrix} b_{11} & \frac{b_{12}}{2} & \dots & \frac{b_{1k}}{2} \\ \frac{b_{12}}{2} & b_{22} & \dots & \frac{b_{2k}}{2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{b_{1k}}{2} & \frac{b_{2k}}{2} & \dots & b_{kk} \end{bmatrix}.$$

El punto estacionario de segundo orden se obtiene derivando $\hat{y}$ con respecto al vector $\mathbf{x}$, es decir,

$$\frac{\partial \hat{y}}{\partial \mathbf{x}} = \mathbf{b} + 2\hat{\mathbf{B}}\mathbf{x}.$$

Igualando la anterior expresión a cero y como $\mathbf{B}$ es no singular, se obtiene el punto estacionario ($\mathbf{x}_s$) dado por

$$\mathbf{x}_s = -\frac{\hat{\mathbf{B}}^{-1}\mathbf{b}}{2}. \quad (12.13)$$

Es importante en esta metodología determinar qué tipo de función se tiene en la obtención del óptimo. Una alternativa de análisis es hacer uso del análisis canónico, el cual se presenta en la siguiente sección.

12.5.2. Análisis canónico

Una vez que se ha encontrado el punto estacionario, generalmente es necesario caracterizar la superficie de respuesta en la vecindad inmediata de este punto. Por caracterizar se entiende determinar si el punto estacionario es el punto de una respuesta máxima, mínima o punto de silla. Por lo general, también se desea estudiar la sensibilidad relativa de la respuesta a las variables $x_1, x_2, \dots, x_k$.

La naturaleza de los puntos estacionarios se determina por los signos de los valores propios de la matriz $\hat{\mathbf{B}}$, para ello se define la matriz $\mathbf{P}$, cuyas columnas corresponden a los vectores propios normalizados, obteniendo

$$\mathbf{\Lambda} = \mathbf{P}^t \hat{\mathbf{B}} \mathbf{P}.$$

Al trasladar el modelo a un nuevo centro, se tiene en cuenta la transformación

$$\mathbf{z} = \mathbf{x} - \mathbf{x}_s.$$

Trasladando el modelo de la ecuación (12.11) a un nuevo centro, originándose la respuesta predicha en el punto estacionario,

$$\begin{aligned} \hat{y} &= b_0 + (\mathbf{z} + \mathbf{x}_s)^t \mathbf{b} + (\mathbf{z} + \mathbf{x}_s)^t \hat{\mathbf{B}} (\mathbf{z} + \mathbf{x}_s) \\ \hat{y} &= [b_0 + \mathbf{x}_s^t \mathbf{b} + \mathbf{x}_s^t \hat{\mathbf{B}} \mathbf{x}_s] + \mathbf{z}^t \mathbf{b} + \mathbf{z}^t \hat{\mathbf{B}} \mathbf{z} + 2\mathbf{x}_s^t \hat{\mathbf{B}} \mathbf{z}. \end{aligned}$$

Reemplazando $\mathbf{x}_s$ obtenido en (12.13) en la expresión anterior, se encuentra

$$\begin{aligned}\hat{y} &= \hat{y}_s + \mathbf{z}^t \mathbf{b} + \mathbf{z}^t \hat{\mathbf{B}} \mathbf{z} - \mathbf{b}^t \hat{\mathbf{B}}^{-1} \hat{\mathbf{B}} \mathbf{z} \\ \hat{y} &= \hat{y}_s + \mathbf{z}^t \hat{\mathbf{B}} \mathbf{z},\end{aligned}\quad (12.14)$$

donde $\hat{y}_s = b_o + \mathbf{x}_s^t \mathbf{b} + \mathbf{x}_s^t \hat{\mathbf{B}} \mathbf{x}_s$ es la respuesta estimada en el punto estacionario, obteniendo así la traslación de los ejes.

Una vez realizada la traslación se hace una rotación de los ejes para eliminar el producto cruzado $\mathbf{z}^t \hat{\mathbf{B}} \mathbf{z}$ en (12.14), para ello se considera la transformación ortogonal $\mathbf{z} = \mathbf{P}\mathbf{w}$, tal que

$$\mathbf{z}^t \hat{\mathbf{B}} \mathbf{z} = \mathbf{w}^t \mathbf{P}^t \hat{\mathbf{B}} \mathbf{P} \mathbf{w} = \mathbf{w}^t \boldsymbol{\Lambda} \mathbf{w} = \lambda_1 w_1^2 + \cdots + \lambda_k w_k^2.$$

Sustituyendo este resultado en la expresión (12.14), se puede escribir finalmente como:

$$\hat{y} = \hat{y}_s + \sum_{i=1}^k \lambda_i w_i^2, \quad (12.15)$$

donde $\lambda_1, \lambda_2, \dots, \lambda_k$ son los valores propios de la matriz $\hat{\mathbf{B}}$ y $w_1, w_2, \dots, w_k$ son llamadas las *variables canónicas*. A esta traslación y rotación de ejes se le llama forma *canónica del modelo*.

Los signos de los valores propios (λ_i) determinan la naturaleza de la superficie de respuesta en el punto estacionario ($\mathbf{x}_s$). Si el punto estacionario está dentro de la región de exploración para ajustar un modelo de segundo orden y si todas las λ_i son positivas, entonces $\mathbf{x}_s$ es un punto de respuesta mínima; si todas las λ_i son negativas, $\mathbf{x}_s$ es un punto de respuesta máxima; y si las λ_i tienen signos diferentes, $\mathbf{x}_s$ es un punto de silla. Además, la superficie presenta una inclinación mayor en la dirección w_i para la que $|\lambda_i|$ es el máximo. Por ejemplo, la figura 12.5 describe un sistema para el que $\mathbf{x}_s$ es un máximo (λ_1 y λ_2 son negativas), con $|\lambda_1| > |\lambda_2|$.

Ejemplo 12.5. *Se realizó un experimento en el cual se considera el efecto de las variables: temperatura de reacción (x_1) y longitud de tiempo de la reacción (x_2) sobre el porcentaje de producción, los datos obtenidos se presenta en la tabla 12.9. En este experimento, el investigador decidió aumentar el diseño factorial 2^2 con dos puntos centrales y cuatro axiales. A este diseño se le llama diseño central compuesto (DCC), el cual se estudiará con mayor detalle en el volumen dos.*

Tabla 12.9: Porcentaje de producción de un producto según la temperatura y el tiempo de reacción

Variables codificadas			Variables originales	
x_1	x_2	% prod	Tem (°C)	Tiempo (seg)
-1	-1	93.6	125.9	171.9
-1	1	91.7	125.9	218.1
1	-1	92.5	145.9	171.9
1	1	92.9	145.9	218.1
0	0	96.2	135.9	195.0
0	0	97.0	135.9	195.0
$-\sqrt{2}$	0	92.7	121.75	195.0
$\sqrt{2}$	0	92.8	150.04	195.0
0	$-\sqrt{2}$	93.4	135.9	162.3
0	$\sqrt{2}$	92.7	135.9	227.7

Para simplificar los cálculos, las variables independientes se codifican como

$$x_1 = \frac{\xi_1 - 135.9}{10} \quad y \quad x_2 = \frac{\xi_2 - 195}{23.1},$$

donde ξ_1 denota la variable natural temperatura y ξ_2 la variable natural tiempo.

Aplicando el método de mínimos cuadrados, se obtiene el modelo en términos de las variables codificadas

$$\hat{y} = 96.60 + 0.03x_1 - 0.31x_2 - 1.98x_1^2 - 1.83x_2^2 + 0.57x_1x_2.$$

En la tabla 12.10, se presentan los coeficientes estimados junto con las desviaciones estándar para el modelo anterior.

Tabla 12.10: Coeficientes estimados al relacionar porcentaje de producción con la temperatura y tiempo de reacción

Efecto	gl	Coeficiente	Desv. coef.	t	Valor p
Constante	1	96.60	0.24	405.51	0.00
Temperat	1	0.03	0.12	0.25	0.81
Tiempo	1	-0.31	0.12	-2.61	0.06
Temperat*Temperat	1	-1.98	0.16	-12.57	0.00
Tiempo*Tiempo	1	-1.83	0.16	-11.62	0.00
Temperat*Tiempo	1	0.57	0.17	3.41	0.03

A partir de los resultados de la tabla 12.11 de análisis de varianza, se concluye que el modelo de segundo orden propuesto no tiene problemas de falta de ajuste (valor $p = 0.92$). Además, la razón F para juzgar la hipótesis $H_0 : \beta_1 = \beta_2 = \beta_{11} = \beta_{12} = \beta_{22} = 0$ es

$$F = \frac{5.09}{0.11} = 44.85,$$

con lo cual se concluye que esta hipótesis se rechaza, existiendo al menos un término del modelo diferente de cero. De los resultados de las tablas, se concluye que la interacción y parte cuadrática del modelo son efectos significativos. Sin embargo, la parte lineal del modelo no es significativa, pero debido a la jerarquía del modelo esta no se debe excluir del mismo para el análisis.

Tabla 12.11: Análisis de varianza para el peso por alimento consumido en los ratones

C. de V.	GL	SC	CM	F	Valor p
Regresión	5	25.45	5.09	44.85	0.00
Lineal	2	0.78	0.39	3.45	0.13
Cuadrática	2	23.35	11.67	102.85	0.00
Interacción	1	1.32	1.32	11.65	0.03
Error	4	0.45	0.11		
Falta de ajuste	3	0.13	0.04	0.14	0.92
Error puro	1	0.32	0.32		
Total	9	25.90			

Como $R_{ajus}^2 = 0.961$, entonces el porcentaje de producción es explicada en un 96.1 % por las variables temperatura y tiempo, cuando se ajusta un modelo de segundo orden.

La localización del punto estacionario se encuentra utilizando la solución general de la ecuación (12.12). Se observa con los datos que

$$b = \begin{pmatrix} 0.03 \\ -0.31 \end{pmatrix} \quad y \quad \hat{B} = \begin{pmatrix} -1.98 & 0.29 \\ 0.29 & -1.83 \end{pmatrix}$$

y, por la ecuación (12.12), el punto estacionario es

$$x_s = -\frac{1}{2} \begin{pmatrix} -0.52 & -0.08 \\ -0.08 & -0.56 \end{pmatrix} \begin{pmatrix} 0.03 \\ -0.31 \end{pmatrix} = \begin{pmatrix} -0.005 \\ -0.086 \end{pmatrix}.$$

Es decir, $x_{1,s} = -0.005$ y $x_{2,s} = -0.086$. En términos de las variables naturales (mediciones originales), el punto estacionario es

$$-0.005 = \frac{\xi_1 - 135.9}{10} \quad -0.086 = \frac{\xi_2 - 195}{23.1},$$

con lo cual se obtiene $\xi_1 = 135.85 \approx 135.9^\circ\text{C}$ y $\xi_2 = 193.02 \approx 193$ segundos. La respuesta predicha en el punto estacionario es $\hat{y}_s = 96.61$.

El análisis canónico, en este caso, se usó para caracterizar la superficie de respuesta. Primero es necesario expresar el modelo ajustado en la forma canónica (12.15). Los valores propios λ_1 y λ_2 se obtienen de la siguiente forma $|\hat{B} - \lambda I| = 0$.

$$\begin{vmatrix} -1.98 - \lambda & 0.29 \\ 0.29 & -1.83 - \lambda \end{vmatrix} = 0.$$

La anterior expresión se reduce a $\lambda^2 + 3.81\lambda + 3.55 = 0$. Al solucionar la ecuación, se tiene $\lambda_1 = -1.61$ y $\lambda_2 = -2.20$. Por lo tanto, la forma canónica del modelo ajustado es

$$\hat{y} = 96.61 - 1.61w_1^2 - 2.20w_2^2. \quad (12.16)$$

Puesto que los dos valores propios son negativos y el punto estacionario está en la región de estudio, se concluye que en este punto hay un máximo, lo cual se corrobora con los gráficos que se presentan en la figura 12.8. Además, como $|\lambda_2| > |\lambda_1|$, entonces la superficie de respuesta cambia más rápidamente en la dirección del eje w_2 . Este cambio es aproximadamente de un 37 % = $\frac{(2.20-1.61)}{1.61} 100$ %.




Figura 12.8: Superficie de respuesta y gráfico de contorno para ajustar el porcentaje de producción en términos de la temperatura y tiempo de reacción.

En algunos problemas de MSR se hace necesario encontrar la relación entre las variables canónicas w_i y las variables diseño x_i . Esto es particularmente cierto cuando es imposible operar el proceso en el punto estacionario. Para ejemplificar, se supone que el proceso no pudo operarse en $\xi_1 = 135.9^\circ\text{C}$ y $\xi_2 = 193$ segundos debido a que esta combinación de factores resulta en un costo excesivo por lo cual se quiere regresar ahora del punto estacionario a un punto con un costo menor sin incurrir en pérdidas considerables en el porcentaje de producción. La forma canónica del modelo indica que la superficie es menos sensible a la pérdida en el porcentaje de producción en la dirección w_1 . La exploración de la forma canónica requiere convertir los puntos del espacio (w_1, w_2) en puntos del espacio (x_1, x_2) .

En general, las variables x se relacionan con las variables canónicas w a través de la expresión

$$w = P^t z = P^t (x - x_s),$$

donde $\mathbf{P}$, como ya se dijo, es una matriz ortogonal ($k \times k$) y sus columnas son los vectores propios normalizados asociados con los λ_i 's. Es decir, si $\mathbf{p}_i$ es la i -ésima columna de $\mathbf{P}$, entonces $\mathbf{p}_i$ es la solución de el siguiente polinomio

$$(\hat{\mathbf{B}} - \lambda_i \mathbf{I})\mathbf{p}_i = \mathbf{0}, \quad (12.17)$$

en el cual se satisface que $\mathbf{p}_i^t \mathbf{p}_i = 1$. En este caso, para $\lambda_i = -1.6091$ la expresión (12.17) tiene la forma

$$\begin{vmatrix} (-1.98 + 1.61) & 0.29 \\ 0.29 & (-1.83 + 1.61) \end{vmatrix} \begin{pmatrix} p_{11} \\ p_{21} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

o, equivalentemente,

$$\begin{aligned} -0.37p_{11} + 0.29p_{21} &= 0 \\ 0.29p_{11} - 0.22p_{21} &= 0. \end{aligned}$$

Solucionando el sistema anterior, sujeto a que $p_{11}^2 + p_{21}^2 = 1$, si $p_{11}^* = 1$, se encuentra $p_{21}^* = 1.29$. Para normalizar esta solución, p_{11}^* y p_{21}^* se dividen entre

$$\sqrt{(p_{11}^*)^2 + (p_{21}^*)^2} = \sqrt{(1)^2 + (1.29)^2} = 1.64,$$

obteniendo así la solución normalizada

$$p_{11} = \frac{1}{1.64} = 0.61 \quad \text{y} \quad p_{21} = \frac{1.29}{1.64} = 0.79,$$

que es la primera columna de la matriz $\mathbf{P}$, observando que $(0.61)^2 + (0.79)^2 = 1$.

Para $\lambda_2 = -2.20$ puede repetirse el procedimiento anterior, obteniéndose los valores $p_{12} = -0.79$ y $p_{22} = 0.61$ como la segunda columna de $\mathbf{P}$. Por lo tanto, se tiene

$$\mathbf{P} = \begin{pmatrix} 0.61 & -0.79 \\ 0.79 & 0.61 \end{pmatrix}.$$

La relación entre las variables $\mathbf{w}$ y $\mathbf{x}$ es:

$$\begin{pmatrix} w_1 \\ w_2 \end{pmatrix} = \begin{pmatrix} 0.61 & -0.79 \\ 0.79 & 0.61 \end{pmatrix}^t \begin{pmatrix} x_1 + 0.004 \\ x_2 + 0.086 \end{pmatrix}$$

o, equivalentemente,

$$\begin{aligned} w_1 &= 0.61x_1 + 0.79x_2 + 0.07 \\ w_2 &= -0.79x_1 + 0.61x_2 + 0.05. \end{aligned}$$

Si quisiera explorarse la superficie de respuesta en la vecindad del punto estacionario, deben determinarse los puntos apropiados en los cuales deben hacerse las observaciones en el espacio (w_1, w_2) y, posteriormente, usar la relación anterior para convertir estos puntos en el espacio (x_1, x_2) para que puedan realizarse los respectivos tratamientos.

12.6. Análisis de cordillera

La forma de la ecuación (12.15) ayuda a dar una mejor interpretación a la superficie de segundo orden. Cuando el punto estacionario x_s se encuentra dentro de la región experimental y, además uno o más de los $\lambda_i \cong 0$, la variable respuesta no es muy sensible a los cambios de w_i . En este caso, en el punto estacionario no hay un máximo o mínimo, por ello la opción es encontrar el “mejor punto posible” dentro de la región experimental. Este punto se ubica sobre la cordillera óptima a partir del centro del diseño y debe tomarse aquel que predice la mejor respuesta sobre la región. Esta búsqueda se hace precisamente con el *análisis de cordillera*, que es muy parecido a la trayectoria en máximo ascenso, pero sobre una superficie con curvatura; mientras que en el método de la trayectoria en máximo ascenso la dirección de movimiento es única, cuando se hace el análisis de cordillera se cambia de rumbo a cada instante.

Otra diferencia importante es que el análisis de cordillera se limita a buscar un solo punto, “el mejor posible”, dentro o en la frontera de la región experimental con base en la respuesta predicha $\hat{y}$, mientras que en la trayectoria en máximo ascenso se busca explorar en cierta dirección más allá de la región experimental y se corre el proceso en cada punto, tratando de determinar el punto de quiebre o cambio de tendencia de la verdadera superficie, por lo tanto son dos objetivos diferentes.

El método de análisis de cordillera consiste en calcular el máximo (o mínimo) en esferas concéntricas hacia el centro del diseño desde una esfera de radio casi cero hasta alrededor de la primera esfera que cubre los puntos experimentales, utilizando un paso pequeño en los radios. El mejor punto posible es aquel que va a predecir el mejor desempeño de la variable respuesta. Con frecuencia, este punto se ubica en la esfera de radio más grande. En el caso de $k = 2$ factores, no son esferas sino circunferencias, y se podrá, con las gráficas de superficie y sus contornos, hacer una mejor aproximación en la búsqueda de la región óptima, pero si $k > 2$, el análisis es más complejo y se recurre a la gráfica de contornos pero realizando cortes y condicionando el modelo para hacer una buena aproximación de la región óptima.

En el desarrollo matemático del análisis de cordillera, se considera el modelo ajustado de segundo orden (12.12) restringido a la esfera centrada en el origen con radio R , es decir,

$$x^t x = \sum_{i=1}^k x_i^2 = R^2.$$

El problema del análisis de cordillera es encontrar el punto sobre la esfera donde la respuesta predicha por el modelo es máxima (o mínima). Usando multiplicadores de Lagrange se plantea la función objetivo:

$$L = b_0 + x^t b + x^t \hat{B}x - \mu(x^t x - R^2).$$

Derivando esta última relación con respecto al vector x e igualando a cero, se obtiene

$$\frac{\partial L}{\partial x} = b + 2\hat{B}x - 2\mu x = 0$$

y, de ahí, se llega al sistema de ecuaciones:

$$(\hat{B} - \mu I)x = -\frac{1}{2}b. \quad (12.18)$$

La solución adecuada de x depende del valor que se considere en R y la buena elección de μ depende de los valores propios de la matriz $\hat{B}$. Para la selección de los valores de μ , se considera que:

1. Si μ excede el valor propio más grande de $\hat{B}$, la solución en (12.18) resultará un máximo absoluto para $\hat{y}$ en $R = (x^t x)^{\frac{1}{2}}$.
2. Si μ es más pequeño que el menor valor propio de la matriz $\hat{B}$, la solución de la ecuación (12.18) resultará en un mínimo absoluto para $\hat{y}$ en $R = (x^t x)^{\frac{1}{2}}$.

La estimación de la región óptima o del punto óptimo está sujeta a la variabilidad, por esta razón, se debe tener en cuenta el error estándar y las regiones de confianza para su debido análisis e interpretación.

A partir del modelo canónico, se puede llevar a cabo el análisis de cordillera cuando uno o más de los λ_i es aproximadamente cero. Si el punto estacionario se encuentra en la región de exploración, se hace la restricción sobre el modelo, el cual queda con una dimensión $k - 1$, y se analiza si se presenta un máximo o un mínimo que depende del signo de λ_i , el cual se puede tomar a partir de un nuevo eje de coordenadas.

Ejemplo 12.6. *Suponga un experimento en donde el problema es maximizar la fuerza de arrastre en soldadura de aluminio en función del tiempo (x_1), potencia (x_2) y fuerza (x_3). Después de realizar el experimento con un punto central, se detecta la presencia de curvatura y se aumenta el experimento para convertirlo en un DCC. Se analizaron los datos y se ajustó el siguiente modelo de la superficie de respuesta de segundo orden:*

$$\hat{y} = 1952 + 117x_1 + 219x_2 - 20x_3 - 95x_1x_2 - 191x_2^2 + 100x_2x_3,$$

el cual explica el 85 % de la variación observada. Mediante el análisis canónico se encuentra que la superficie descrita por este modelo es un punto de silla. Para ello basta verificar que los valores propios de la matriz de coeficientes de segundo orden

$$\hat{\mathbf{B}} = \begin{pmatrix} 0.0 & -47.5 & 0.0 \\ -47.5 & -191.0 & 50.0 \\ 0.0 & 50.0 & 0.0 \end{pmatrix}$$

y que tiene por valores propios a $\lambda_1 = 0$, $\lambda_2 = 22.3$ y $\lambda_3 = -213.3$, como son de signos contrarios, el punto estacionario es un punto de silla. Por lo tanto, es apropiado realizar el análisis de cordillera para determinar el punto óptimo dentro de la región experimental, la cual se encuentra en una esfera de radio $\sqrt{3} = 1.73$ que corresponde a la distancia entre los vértices del cubo y su centro. De acuerdo con el procedimiento descrito, para cada punto sobre la cordillera óptima se resuelve el sistema de ecuaciones:

$$\begin{pmatrix} (0 - \mu) & -47.5 & 0 \\ -47.5 & (-191 - \mu) & 50 \\ 0 & 50 & (0 - \mu) \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} -58.5 \\ -109.5 \\ 10.0 \end{pmatrix}.$$

Escogiendo μ mayor que el valor más grande de la matriz $\hat{\mathbf{B}}$, en este caso $\mu > 22.3$, se puede encontrar un máximo sustituyendo, como un primer intento, por $\mu = 30$, se obtiene como solución el vector $(1.94, 0.0033, -0.33)$, el cual se ubica sobre la esfera de radio 1.97. Para obtener un punto sobre la cordillera óptima en una esfera más pequeña, se elige un valor de μ un poco más grande. Resolviendo el sistema de ecuaciones para varios valores de μ , se obtiene la tabla 12.12 de análisis de cordillera.

Tabla 12.12: Análisis de cordillera para la fuerza de arrastre

μ	x_1	x_2	x_3	Radio	$\hat{y}$
30	1.94	0.003	-0.33	1.97	2185.58
31	1.80	0.054	-0.23	1.82	2167.99
32	1.69	0.095	-0.16	1.70	2155.24
33	1.60	0.127	-0.11	1.60	2145.43
34	1.50	0.153	-0.07	1.51	2135.06
35	1.43	0.175	-0.03	1.44	2128.08

Estos seis puntos se ubican sobre la cordillera óptima y se observa que a partir de $\mu = 32$ se encuentran adentro de la esfera de radio 1.73. Sin embargo, la coordenada de la variable codificada x_1 para la esfera de radio 1.7 aún es muy grande en términos del rango experimental utilizado (se utilizó un rango de $-1.28 \leq x_1 \leq 1.28$ para cada factor) y es posible que ni siquiera pueda correrse al nivel 1.69. Si este fuera el

caso, se elige como punto óptimo el que está sobre la esfera más grande para el cual el nivel de la variable x_1 sí pueda presentarse. No necesariamente su coordenada tiene que ser menor a 1.28, pero sí debe estar relativamente cercana a este valor. Una posibilidad es realizar el proceso en dos o tres puntos, ubicados alrededor de la frontera de la región experimental, y elegir el mejor de ellos.

Las coordenadas de los factores x_2 y x_3 se mantienen en el rango experimental utilizado, por eso no son variables determinantes en la elección del punto óptimo. En la última columna de la tabla 12.12, se reporta la respuesta predicha $\hat{y}$ para cada punto sobre la cordillera óptima. Esta fuerza de arrastre predicha indica cuál es la fuerza esperada en la combinación de niveles correspondientes. Al realizar las corridas confirmatorias del proceso sobre el punto seleccionado, se logra determinar si la respuesta predicha en él se parece a la respuesta observada.

12.7. Implementación en SAS

A partir de los datos de los ejemplos presentados a lo largo del capítulo, se presentan a continuación los programas en el paquete estadístico SAS a través del cual se obtuvieron los diversos resultados expuestos en los ejemplos: 12.1, 12.3 y 12.5.

```

/*****/
/* Lectura de los datos del ejemplo 12.1 */
/*****/

DATA EJEMPLO121;
INPUT DOSIS TIEMPO REP PESO @@;
CARDS;
0.3 1 1 5.63 0.3 1 2 6.42 0.3 5 1 11.57
0.3 5 2 12.16 0.3 9 1 12.68 0.3 9 2 13.31
0.7 1 1 1.38 0.7 1 2 1.94 0.7 5 1 5.72
0.7 5 2 4.69 0.7 9 1 8.28 0.7 9 2 7.73
;

/*****/
/* Con el procedimiento RSREG se obtiene la superficie de respuesta */
/*****/

PROC RSREG DATA=EJEMPLO121 OUT=SUPER1;
MODEL PESO=DOSIS TIEMPO/ACTUAL LACKFIT RESIDUAL PREDICT PRESS;

```

```

/*****/
/* Lectura de los datos del ejemplo 12.3 */
/*****/

```

```

DATA EJEMPLO123;
INPUT TEMP TIEMPO REP PUREZA @@;
CARDS;
70 30 1 49.8 70 30 2 48.1 90 30 1 57.3 90 30 2 52.3
70 90 1 65.7 70 90 2 69.4 90 90 1 73.1 90 90 2 77.8
;

```

```

PROC RSREG DATA=EJEMPLO123 OUT=RESI;
MODEL PUREZA= TEMP TIEMPO/ACTUAL LACKFIT RESIDUAL
PREDICT PRESS;

```

```

/*****/
/* Lectura de los datos del ejemplo 12.5 */
/*****/

```

```

DATA EJEMPLO125;
INPUT TEMP TIEMPO REP PRODU @@;
CARDS;
125.9 171.9 1 93.6 125.9 218.1 1 91.7
145.9 171.9 1 92.5 145.9 218.1 1 92.9
135.9 195.0 1 96.2 135.9 195.0 2 97.0
121.7579 195.0 1 92.7 150.0421 195.0 1 92.8
135.9 162.3317 1 93.4 135.9 227.6683 1 92.7
;

```

```

/*****/
/* GRÁFICO DE INTERACCIÓN */
/*****/

```

```

PROC PLOT DATA=EJEMPLO125 UNIFORM HPERCENT=50 VPERCENT=50;
PLOT PRODU*TEMP=TIEMPO/BOX OVERLAY;

```

```

/*****/
/* GRÁFICOS SUPERFICIES DE RESPUESTA Y CURVAS DE NIVEL */
/*****/

```

```

/*****/
/* PROC G3GRID: Usando interpolación, este procedimiento calcula para */
/* una malla rectangular (X,Y) los valores de Z creando así una red */
/* (x,y,z) de datos que permiten construir un gráfico en tres dimen\- */
/* siones. En este ejemplo, con datos de la variable TEMP y TIEMPO, se */
/* calculan los valores de la variable respuesta PRODU, para una malla */
/* de 2 en el eje 1 y 2 en el eje 2. Los valores interpolados se guardan*/
/* en el archivo CUAD para luego graficarlos. */
/*****/

```



```
TITLE H=1.3 F=SWISS C=BLACK 'SUPERFICIE DE RESPUESTA';
```

```
PROC G3GRID DATA=EJEMPLO125 OUT=CUAD;
GRID TEMP*TIEMPO=PRODU/ AXIS1=121.75 TO 150.04 BY 2 AXIS2=162.3 TO
227.7 BY 2 SPLINE;
```

```
/******
/* PROC G3D: Construye gráficos en tres dimensiones. Las opciones */
/* yticknum=5 y xticknum=6 indican el número de valores que se rotulan */
/* en el eje Y y X, respectivamente. */
/******
```

```
PROC G3D DATA=CUAD;
PLOT TEMP*TIEMPO=PRODU/ YTICKNUM=5 XTICKNUM=6 CTOP=RED;
```

```
TITLE H=1.3 F=SWISS C=BLACK ' CURVAS DE NIVEL ';
```

```
/******
/* PROC GCONTOUR: Construye las curvas de nivel de un gráfico en tres */
/* dimensiones. Las opciones yticknum=8 xticknum=8 indican el número */
/* de valores que se rotulan en el eje Y y en eje X, respectivamente; */
/* LEVELS 91.7,92,...,etc indican las curvas de nivel a graficar y */
/* LLEVELS indica el tipo de linea correspondiente a cada nivel. */
/******
```

```
PROC GCONTOUR DATA=CUAD;
PLOT TEMP*TIEMPO=PRODU/YTICKNUM=8 XTICKNUM=8
LEVELS=91.7 92 93 94 95 96 97 LLEVELS=1 2 3 4 5 6 7 8
NOLEGEND AUTOLABEL;
```

```
/******
/* Con el procedimiento RSREG se obtiene la superficie de respuesta. En*/
/* dado caso que el punto obtenido fuese un punto de silla, a través de*/
/* la opción RIDGE MAXIMUM se podría maximizar la respuesta dentro de */
/* la región experimental. Otra posibilidad, es utilizar el procedi\- */
/* miento del análisis de diseño de experimentos que trae la interfa\- */
/* ce ADX de SAS. */
/******
```

```
PROC RSREG DATA=EJEMPLO125 OUT=PRODUC;
MODEL PRODU= TEMP TIEMPO/ACTUAL LACKFIT RESIDUAL PREDICT PRESS;
RIDGE MAXIMUM /*MINIMUM*/;
RUN;
```

12.8. Implementación en R

A partir de los datos de los ejemplos [12.1](#), [12.2](#), [12.3](#) y [12.5](#), se presenta a continuación el programa en el software estadístico R.

```
#####
## Ejemplo 12.1 ##
#####

ejemplo12.1 <- data.frame(dosis=c(rep(c(0.3,0.3,0.7,0.7),3)),
  tiempo=c(1,5,1,5,1,9,1,9,5,9,5,9),
  rep=factor(c(1,2,1,2,2,1,2,1,1,2,1,2)),
  peso=c(5.63,12.16,1.38,4.69,6.42,12.68,1.94,8.28,11.57,13.31,5.72,7.73))

# Obtención de la Figura 12.3
interaction.plot(ejemplo12.1$tiempo,ejemplo12.1$dosis,ejemplo12.1$peso,col=1,
  xlab='Tiempo',ylab='Peso de la comida ingerida',leg.bty='o',cex=1.5,
  trace.label=deparse(substitute(Dosis)))

# Coeficientes del modelo
modelo12.1.1 <- lm(peso ~ dosis+tiempo+dosis*tiempo+I(tiempo^2),
  data=ejemplo12.1)
# Coeficientes estimados al ajustar el modelo
summary(modelo12.1.1)

# Análisis de varianza para el peso por alimento consumido en los ratones
anova(modelo12.1.1)
# Predicciones y residuales al ajustar el modelo
predict(modelo12.1.1)
residuals(modelo12.1.1)

# Otra opción
# F0, TWI, PQ, SO (para "first-order", "two-way interaction", "pure
# quadratic" y "second-order", respectivamente)
library("rsm")
modelo12.1.2 <- rsm(peso ~ F0(dosis, tiempo)+TWI(dosis, tiempo)+I(tiempo^2),
  data=ejemplo12.1)
summary(modelo12.1.2)

#####
## Ejemplo 12.3 ##
#####

summary(modelo12.1.2)$lof
```

```
#####
## Ejemplo 12.3 ##
#####
```

```
ejemplo12.3 <- data.frame(temp=c(70,70,70,70,90,90,90,90),
  tiempo=c(30,90,30,90,30,90,30,90),
  rep=factor(c(1,1,2,2,1,1,2,2)),
  pureza=c(49.8,65.7,48.1,69.4,57.3,73.1,52.3,77.8))

# Creación de variables codificadas
msr1 <- coded.data(ejemplo12.3, x1~(temp-80)/10, x2~(tiempo-60)/30)

# Coeficientes del modelo en variables codificadas
modelo12.3.1 <- rsm(pureza ~ F0(x1, x2), data = msr1)
summary(modelo12.3.1)

# Coeficientes del modelo en variables originales
modelo12.3.2 <- rsm(pureza ~ F0(temp, tiempo), data = ejemplo12.3)
summary(modelo12.3.2)

# Predicciones y residuales al ajustar el modelo
predict(modelo12.3.2)
residuals(modelo12.3.2)
```

```
#####
## Ejemplo 12.5 ##
#####
```

```
ejemplo12.5 <- data.frame(temperatura=c(125.9,145.9,135.9,121.7579,135.9,
  125.9,145.9,135.9,150.0421,135.9),
  tiempo=c(171.9,171.9,195.0,195.0,162.3317,218.1,218.1,195.0,
  195.0,227.6683),rep=factor(c(1,1,1,1,1,1,1,2,1,1)),
  produ=c(93.6,92.5,96.2,92.7,93.4,91.7,92.9,97.0,92.8,92.7))

# Creación de variables codificadas
msr2<-coded.data(ejemplo12.5,x1~(temperatura-135.9)/10,x2~(tiempo-195)/23.1)

# Coeficientes del modelo en variables codificadas
modelo12.5 <- rsm(produ ~ S0(x1, x2), data = msr2)
summary(modelo12.5)

## Superficie de respuesta y gráfico de contorno para ajustar el porcentaje
## de producción en términos de la temperatura y tiempo de reacción.
par(mfrow = c(1,2))
contour(modelo12.5,~ x1+x2,image=TRUE)
persp(modelo12.5,~ x1+x2,col=rainbow(50),contours="colors")

# Lo mismo, pero en blanco y negro
par(mfrow = c(1,2))
```

```
contour(modelo12.5, ~ x1+x2)
persp(modelo12.5, ~ x1+x2, contours="black")
```

12.9. Ejercicios

1. ¿Cuándo se recomienda aplicar la metodología de superficie de respuesta? ¿Cuál es la diferencia entre tratamiento ganador y tratamiento óptimo?
2. ¿Por qué es recomendable trabajar el análisis en unidades codificadas en lugar de las unidades originales? Explique qué son los modelos de primer orden, de segundo orden y jerárquicos.
3. ¿En qué consiste el análisis canónico y cuándo se aplica? ¿Cuáles son los diferentes tipos de superficies que se pueden obtener?
4. En una empresa dedicada a anodizar artículos de aluminio (baterías de cocina), el anodizado se logra en una solución a base de ácidos (sulfúrico, cítrico y bórico) y dicromato de aluminio. En este proceso se controla el PH de la solución, temperatura, corriente y tiempo de permanencia. Debido al poco grosor del anodizado, han aumentado las quejas por la poca resistencia y durabilidad del producto. Para resolver este problema, se decide estudiar mediante un experimento la relación del PH y la temperatura con el grosor del anodizado. Los datos se presentan en la siguiente tabla

PH	Temperatura	Espesor
1,2	-8	9
1,8	-8	14
1,2	8	10
1,8	8	19
1,2	-8	8
1,8	-8	12
1,2	8	11
1,8	8	20
1,5	0	14
1,5	0	13

- a. Proponga un modelo para el diseño que utilizaron los experimentadores.
- b. Encuentre el modelo que mejor describe el comportamiento. Realice la prueba de bondad de ajuste y concluya.

- c. Valide los supuestos sobre el modelo propuesto.
 - d. Con el modelo propuesto, liste cinco puntos en la dirección de máximo ascenso, utilice un paso de 0.3 en el factor de mayor influencia.
 - e. Explique qué se hace después con los puntos encontrados.
5. La región de experimentación de tres factores son el tiempo ($40 \leq T_1 \leq 80$ mín), la temperatura ($200 \leq T_2 \leq 300^\circ\text{C}$) y la presión ($20 \leq P \leq 50$ psi). Se ha ajustado un modelo de primer orden en variables codificadas a los datos del rendimiento en un diseño 2^3 . El modelo ajustado es:
- $$\hat{y} = 30 + 5x_1 + 2.5x_2 + 3.5x_3.$$
- a. Encontrar y graficar la trayectoria de máximo ascenso ignorando la presión.
 - b. Encontrar y graficar la trayectoria de máximo ascenso incluyendo la presión.
 - c. Comparar los dos resultados y comentar las conclusiones.
6. Los siguientes datos fueron recolectados por un ingeniero químico, él quiere observar la relación que existe entre el tiempo de filtración con la temperatura y la presión.

Temperatura	Presión	Tiempo de filtración
-1	-1	54
-1	1	45
1	-1	32
1	1	47
$-\sqrt{2}$	0	50
$\sqrt{2}$	0	53
0	$-\sqrt{2}$	47
0	$\sqrt{2}$	51
0	0	41
0	0	39
0	0	44
0	0	42
0	0	40

- a. Proponga un modelo para el diseño que utilizaron los experimentadores.
- b. Ajuste un modelo de segundo orden y compruebe que es adecuado.

- c. Represente gráficamente la superficie de respuesta obtenida.
- d. Encuentre la ecuación canónica ¿Qué tipo de superficie describe éste modelo?
- e. ¿Qué condiciones de operación se recomendarían si se desea que el tiempo de filtración sea mínimo?

7. Suponga que en un proceso se ajustó el modelo

$$\hat{y} = 10.46 - 0.57x_1 + 0.18x_2 + 0.45x_3 - 0.67x_1^2 + 0.56x_2^2 - 0.27x_3^2 - 0.67x_1x_2 + 1.18x_1x_3 + 0.23x_2x_3.$$

- a. Encuentre el punto estacionario y diga de qué tipo es.
 - b. Si se obtiene un punto de silla, realice un análisis de cordillera para determinar el mejor punto posible dentro de una esfera de radio máximo de 2.5.
8. Los datos que se muestran en la siguiente tabla se recolectaron en un experimento para optimizar el crecimiento de un cristal como una función de tres variables x_1 , x_2 y x_3 . En este ensayo son deseables los valores grandes de y (rendimiento en gramos).

x_1	x_2	x_3	y
-1	-1	-1	66
-1	-1	1	70
-1	1	-1	78
-1	1	1	60
1	-1	-1	80
1	-1	1	70
1	1	-1	100
1	1	1	75
-1.682	0	0	100
1.682	0	0	80
0	-1.682	0	68
0	1.682	0	63
0	0	-1.682	65
0	0	1.682	82
0	0	0	113
0	0	0	100
0	0	0	118
0	0	0	88
0	0	0	100
0	0	0	85

- a. Ajuste un modelo de segundo orden y analice la superficie ajustada.

- b. ¿Hay problemas de falta de ajuste en el modelo propuesto?
- c. Valide los supuestos sobre el modelo propuesto.
- d. ¿En qué porcentaje es explicado el crecimiento por las variables explicativas?
- e. Encuentre la ecuación canónica.
- f. ¿Bajo qué conjunto de condiciones se alcanza el crecimiento máximo?

9. Considere el modelo ajustado de segundo orden

$$\hat{y} = 8.25 + 0.0396x_1 + 0.1884x_2 - 0.4313x_1^2 - 0.3563x_2^2 + 0.3x_1x_2.$$

- a. Dibuje la superficie de respuesta descrita por el modelo. ¿Qué tipo de superficie es?
- b. Localice las coordenadas del punto estacionario.
- c. Encuentre un punto sobre la dirección de mínima pérdida a partir del punto estacionario.

normal

13.1. Introducción

La literatura estadística ha sido bastante extensa al abordar el análisis con respuesta continua normal, generalmente se asume en estos ensayos que la varianza es constante, caso difícil de mantener en ensayos con tratamientos. A partir de la década de los 80, se ha venido formalizando el uso de métodos estadísticos para abordar el problema de análisis de datos con respuestas relacionadas con conteos (conteos de defectos en un proceso de producción, conteos de células, conteos de insectos enfermos de una determinada patología, etc.), proporción (proporción de piezas defectuosas en un proceso, proporción de plantas que germinan en un determinado cultivo, proporción de personas que se curan cuando se aplica un medicamento, etc.), proporción continua (porcentaje de desgaste de una máquina, porcentaje de infección de una planta, etc.) y tiempos de falla, todos de interés en los ensayos de tratamientos. Estos tipos de respuesta siguen una función de probabilidad: Poisson para conteos, Binomial para proporciones, Beta para proporciones continuas y Gamma para tiempos de falla. La característica de estos casos de información es que la varianza no es constante y, además, es una función de la media (en el caso de la distribuciones Poisson, Binomial y Gamma), contrario a lo que sucede con datos bajo distribución normal en los que el uso de métodos de estimación como el de mínimos cuadrados proporciona estimadores con mínima varianza.

Muchos investigadores procurando encontrar varianzas constantes hacen uso de transformaciones y aplican mínimos cuadrados para obtener estimaciones y ajustar los modelos. Este procedimiento en las actuales circunstancias no es adecuado. Por lo general, lo adecuado es analizar este tipo de datos con modelos lineales generalizados (MLG) y modelos con presencia de sobredispersión (MS). En este capítulo se aborda de forma general el uso de MLG y MS, enfatizando en los diseños experimentales con arreglos factoriales y siguiendo las propuestas de Nelder y Wedderburn (1972), McCullagh y Nelder (1989), Myers y Montgomery (1997), Lewis, Montgomery y Myers (2001a), Lewis, Montgomery y Myers (2001b) y Myers, Montgomery, Vinning y Robinson (2010). Se presentan algunas aplicaciones haciendo uso de los procedimientos GLM y GENMOD de SAS, así como su implementación en R (R Development Core Team 2020).

El procedimiento GENMOD de SAS ajusta los MLG por el método de estimación de máxima verosimilitud ajustando el vector de parámetros mediante métodos iterativos, como se observa en Nelder y Wedderburn (1972), McCullagh y Nelder (1989) y Hinde y Demétrio (1998), entre otros. En este procedimiento, los errores estándar y los valores p asociados con

la estimación asintótica de los parámetros están basados en estimadores asintóticamente normales.

13.2. Familia exponencial

En este capítulo se describe la familia exponencial, la cual ha sido fuertemente estudiada a lo largo de varias décadas; los modelos lineales generalizados han tenido un desarrollo acelerado durante las últimas tres décadas, lo que obliga al lector atraído por el tema a la revisión de muchos de los artículos referidos a lo largo del texto.

Muchas distribuciones conocidas pueden ser reunidas en una familia de distribuciones llamada familia exponencial. Por ejemplo, pertenecen a esta familia las distribuciones normal, binomial, binomial negativa, gama, Poisson, normal inversa, multinomial, beta, logarítmica, Rayleigh, entre otras. Esta familia de distribuciones fue propuesta independientemente por Koopman, Pitman y Darmois a través del estudio de propiedades de suficiencia estadística (McCullagh y Nelder 1989, Dobson 2008). El concepto de familia exponencial fue introducido por Fisher, pero los modelos para distribuciones de la familia exponencial aparecen a finales del siglo XIX y fueron desarrollados por Maxwell, Boltzmann y Gibbs. La familia exponencial cobra mayor relevancia en el área de los modelos de regresión a partir del trabajo pionero de Nelder y Wedderburn (1972), quienes definieron los modelos lineales generalizados. Estos modelos se popularizaron inicialmente en Inglaterra y, posteriormente, en Estados Unidos y Europa en la década de los 80.

Si una distribución pertenece a la familia exponencial uniparamétrica, tiene una función de densidad que se puede escribir de la siguiente forma:

$$f(y; \theta) = h(y) \exp \{ \eta(\theta) t(y) - b(\theta) \}, \quad (13.1)$$

donde las funciones $\eta(\theta)$, $b(\theta)$, $t(y)$ y $h(y)$ asumen valores en subconjuntos de la recta real. El soporte de la familia exponencial (13.1) es el conjunto $\{y : f(y; \theta) > 0\}$ y no depende de θ .

Dentro del campo de los modelos lineales es usual trabajar con una variación de la familia exponencial (13.1) en su forma canónica ($\eta(\theta) = \theta$, $t(y) = y$), la cual incluye un parámetro de dispersión $\phi > 0$, así:

$$f(y; \theta, \phi) = \exp \left\{ \frac{1}{\phi} [y\theta - b(\theta)] + c(y, \phi) \right\} \quad (13.2)$$

La tabla 13.1 muestra como algunas de las distribuciones mas conocidas pueden ser escritas en la forma (13.2).

Tabla 13.1: Algunas distribuciones de la familia (13.2)

Distribución	ϕ	θ	$b(\theta)$	$c(y, \phi)$	$V(\mu)$
$N(\mu, \sigma^2)$	σ^2	μ	$\frac{\theta^2}{2}$	$-\frac{1}{2} \left[\frac{y^2}{\sigma^2} + \ln(2\pi\sigma^2) \right]$	1
$P(\mu)$	1	$\ln \mu$	e^θ	$-\ln y!$	μ
$B(m, \pi)$	1	$\ln \left(\frac{\pi}{1-\pi} \right)$	$m \ln(1 + e^\theta)$	$\ln \binom{m}{y}$	$\frac{1}{m} \mu(m - \mu)$
$BN(\mu, k)$	1	$\ln \left(\frac{\mu}{\mu + k} \right)$	$-k \ln(1 - e^\theta)$	$\ln \left[\frac{\Gamma(k+y)}{\Gamma(k)y!} \right]$	$\mu \left(\frac{\mu}{k} + 1 \right)$
$\Gamma(\mu, v)$	v^{-1}	$-\frac{1}{\mu}$	$-\ln(-\theta)$	$v \ln(vy) - \ln y - \ln \Gamma(v)$	μ^2
$NI(\mu, \sigma^2)$	σ^2	$-\frac{1}{2\mu^2}$	$-(-2\theta)^{-1/2}$	$-\frac{1}{2} \left[\ln(2\pi\sigma^2 y^3) + \frac{1}{\sigma^2 y} \right]$	μ^3

13.2.1. Momentos de la familia exponencial

La función generadora de momentos de la familia (13.2) esta dada por:

$$M(t; \theta, \phi) = E(e^{tY}) = \exp \left\{ \frac{1}{\phi} b(\phi t + \theta) - b(\theta) \right\}.$$

La función generadora de cumulantes correspondiente a la familia (13.2) esta dada por:

$$\varphi(t; \theta, \phi) = \ln M(t; \theta, \phi) = \frac{1}{\phi} b(\phi t + \theta) - b(\theta). \quad (13.3)$$

Derivando (13.3) sucesivamente con respecto a t , se tiene:

$$\varphi^{(r)}(t; \theta, \phi) = \phi^{(r-1)} b^{(r)}(\phi t + \theta),$$

donde $b^{(r)}$ es la r -ésima derivada de $b(\cdot)$ con respecto a t . Para $t = 0$, se obtiene el r -ésimo cumulante de la familia (13.2),

$$\kappa_r = \phi^{(r-1)} b^{(r)}(\theta).$$

De donde se observa que:

$$\begin{aligned} \mu = E(Y) &= \kappa_1 = b'(\theta) \\ \sigma^2 = Var(Y) &= \kappa_2 = \phi b''(\theta) = \phi V(\mu). \end{aligned}$$

La expresión $\sigma^2 = \phi V(\mu)$ muestra que para las distribuciones de la familia exponencial existe una relación entre la media y la varianza, como se muestra en la tabla 13.1. Esta relación fue estudiada con mas detalle por Wedderburn (1974), dando origen al método de quasiverosimilitud.

13.3. Modelos lineales generalizados

Se requiere de un modelo experimental que sea lo más simple posible y describa bien los datos observados en áreas como agricultura, ecología, economía, ingeniería, medicina, zootecnia, etc. Nelder y Wedderburn (1972) mostraron que una serie de técnicas estadísticas comúnmente usadas por separado pueden ser formuladas de una manera unificada como una clase de modelos de regresión. A esta teoría unificadora de modelamiento estadístico (una extensión de los modelos clásicos de regresión), le dieron el nombre de modelos lineales generalizados. Estos modelos envuelven una variable respuesta univariada, variables explicativas y una muestra aleatoria de n observaciones independientes en las cuales:

- La variable respuesta Y_i , $i = 1, \dots, n$, **componente aleatorio** del modelo, tiene una distribución perteneciente a la familia (13.2) con valor esperado μ_i .
- Las variables explicativas asociadas al i -ésimo individuo ($i = 1, \dots, n$), $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{ki})$, entran en forma de una estructura lineal acompañadas del vector de parámetros $\boldsymbol{\beta}$, constituyendo el **componente sistemático** del modelo denotado por $\eta_i = \mathbf{x}_i^t \boldsymbol{\beta}$.
- Un enlace es hecho entre los componentes aleatorio y sistemático del modelo a través de una función adecuada g , llamada **función de enlace**, la cual conecta el predictor lineal con una función de la media μ_i mediante la expresión

$$g(\mu_i) = \eta_i, \quad i = 1, \dots, n.$$

En modelos lineales clásicos, la media y el predictor lineal son idénticos así que la función de enlace identidad es adecuada, ya que η_i y μ_i pueden asumir cualquier valor en la recta real. Por ejemplo, cuando se trabaja con datos de conteo y la distribución de Poisson, se debe cumplir que $\mu_i > 0$, para todo i . Así que la identidad como función de enlace es menos atractiva, ya que permite a η_i tomar valores negativos mientras que μ_i no puede hacerlo. En este caso, la función de enlace $\eta_i = g(\mu_i) = \ln(\mu_i)$, $i = 1, \dots, n$, con inversa $e^{\eta_i} = \mu_i$ resuelve el problema en mención.

En el caso de la distribución binomial, se debe cumplir que $0 < \mu_i < 1$, $i = 1, \dots, n$; así que una función de enlace debe satisfacer la condición de asignar a cualquier número en el intervalo $(0, 1)$ un único valor de la recta real. Para este caso, se consideran las tres principales funciones de enlace:

1. Logit

$$\eta_i = \ln \left(\frac{\mu_i}{1 - \mu_i} \right), \quad i = 1, \dots, n.$$

2. Probit

$$\eta_i = \Phi^{-1}(\mu_i), \quad i = 1, \dots, n,$$

donde $\Phi(\mu_i)$ es la función de distribución acumulativa normal estándar.

3. Complemento log-log

$$\eta_i = \ln[-\ln(1 - \mu_i)], \quad i = 1, \dots, n.$$

Aranda-Ordaz (1981) propuso una familia de funciones de enlace para analizar datos en forma de proporciones dada por:

$$\eta_i = \ln \left[\frac{(1 - \pi_i)^{-\lambda} - 1}{\lambda} \right], \quad i = 1, \dots, n,$$

siendo λ una constante desconocida que tiene como casos particulares el modelo logístico para $\lambda = 1$ y el complemento log-log para $\lambda \rightarrow 0$.

Otra familia importante de funciones de enlace fue propuesta por Box y Cox (1964), utilizada principalmente para datos con media positiva es la familia potencia que esta especificada por:

$$\eta_i = \begin{cases} \frac{\mu_i^\lambda - 1}{\lambda} & \text{si } \lambda \neq 0, \\ \ln \mu_i & \text{si } \lambda = 0. \end{cases} \quad i = 1, \dots, n, \quad (13.4)$$

Cada una de las distribuciones de la tabla 13.1 tiene una función de enlace especial para la cual existen estadísticos suficientes de la misma dimensión de β . Estos enlaces canónicos ocurren cuando $\theta = \eta$, donde θ es el parámetro canónico mostrado en la tabla 13.1. Los enlaces canónicos para las distribuciones ya tratadas se muestran en la tabla 13.2.

Tabla 13.2: Enlaces canónicos

Distribución	Enlace
Normal	$\eta_i = \mu_i$
Poisson	$\eta_i = \ln \mu_i$
Binomial	$\eta_i = \ln \left(\frac{\pi_i}{1 - \pi_i} \right)$
Gamma	$\eta_i = \mu_i^{-1}$
Normal inversa	$\eta_i = \mu_i^{-2}$

13.3.1. Estimación de parámetros en un MLG

El método utilizado para la estimación de parámetros en un MLG es el de máxima verosimilitud. En el caso de la familia (13.2), la log-verosimilitud para una muestra de n observaciones esta dada por:

$$\ell(\beta) = \sum_{i=1}^n \left[\frac{y_i - b(\theta_i)}{\phi} + c(y, \phi) \right].$$

Como es usual, el método busca maximizar la expresión anterior. Al utilizar la regla de la cadena en el proceso de derivación, se tiene

$$U_r = \frac{\partial \ell(\beta)}{\partial \beta_r} = \frac{1}{\phi} \sum_{i=1}^n \frac{\partial \ell(\beta)}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \eta_i} \frac{\partial \eta_i}{\partial \beta_r}.$$

Lo que se reduce a

$$U_r = \frac{1}{\phi} \sum_{i=1}^n \frac{(y_i - \mu_i)}{V(\mu_i)} \frac{\partial \mu_i}{\partial \eta_i} x_{ir}.$$

El estimador de máxima verosimilitud $\hat{\beta}$ del vector de parámetros β se obtiene igualando U_r a cero para $r = 1, 2, \dots, k$. En general, las ecuaciones $U_r = 0$ son no lineales y tienen que ser resueltas por métodos numéricos como el de Fisher-Scoring, el cual suministra una expresión para la solución de $\hat{\beta}$ y utiliza dentro de su procedimiento la matriz de información de Fisher $\mathcal{J}$ y el vector U en la iteración m , en términos matemáticos la expresión es la siguiente:

$$\beta^{(m+1)} = \beta^{(m)} + (\mathcal{J}^{-1})^{(m)} U^{(m)}. \quad (13.5)$$

Premultiplicando por $\mathcal{J}^{(m)}$ a (13.5), se tiene

$$\mathcal{J}^{(m)} \beta^{(m+1)} = \mathcal{J}^{(m)} \beta^{(m)} + U^{(m)}. \quad (13.6)$$

Los elementos de $\mathcal{J}$ se obtienen de la siguiente igualdad:

$$\begin{aligned} \mathcal{J}_{r,s} &= -E \left(\frac{\partial^2 \ell(\beta)}{\partial \beta_r \partial \beta_s} \right) = E \left(\frac{\partial \ell(\beta)}{\partial \beta_r} \frac{\partial \ell(\beta)}{\partial \beta_s} \right) = E(U_r U_s) \\ &= E \left(\frac{1}{\phi^2} \sum_{i=1}^n \frac{(y_i - \mu_i)^2}{V(\mu_i)^2} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ir} x_{is} \right) \\ &= \frac{1}{\phi^2} \sum_{i=1}^n \frac{1}{V(\mu_i)^2} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ir} x_{is} V ar(Y_i) \\ &= \frac{1}{\phi^2} \sum_{i=1}^n \frac{1}{V(\mu_i)^2} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ir} x_{is} V(\mu_i) \phi \end{aligned}$$

$$\begin{aligned}\mathcal{J}_{r,s} &= \frac{1}{\phi} \sum_{i=1}^n \frac{1}{V(\mu_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ir} x_{is} \\ &= \frac{1}{\phi} \sum_{i=1}^n w_i x_{ir} x_{is},\end{aligned}$$

donde $w_i = \frac{1}{V(\mu_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2$.

Luego, la matriz de información de Fisher para β tiene la forma

$$\mathcal{J} = \frac{1}{\phi} X^t W X, \quad (13.7)$$

con $W = \text{diag}\{w_1, \dots, w_n\}$. Nelder y Wedderburn (1972) mostraron que la matriz de varianza-covarianza asintótica para $\hat{\beta}$ está dada por:

$$\text{Var}(\hat{\beta}) = \mathcal{J}^{-1}.$$

Al expresar el vector U en forma matricial se tiene

$$U = \frac{1}{\phi} X^t W H (Y - \mu), \quad (13.8)$$

donde $H = \text{diag}\left(\frac{\partial \eta_i}{\partial \mu_i}\right)$ es una matriz diagonal formada por las primeras derivadas de la función de enlace. Reemplazando (13.7) y (13.8) en (13.6) se tiene:

$$\begin{aligned}\frac{1}{\phi} X^t W^{(m)} X \beta^{(m+1)} &= \frac{1}{\phi} X^t W^{(m)} X \beta^{(m)} + \frac{1}{\phi} X^t W^{(m)} H^{(m)} (Y - \mu^{(m)}) \\ X^t W^{(m)} X \beta^{(m+1)} &= X^t W^{(m)} \left[\eta^{(m)} + H^{(m)} (Y - \mu^{(m)}) \right] \\ X^t W^{(m)} X \beta^{(m+1)} &= X^t W^{(m)} \mathbf{z}^{(m)},\end{aligned}$$

donde se define una variable dependiente ajustada $\mathbf{z}^{(m)} = \eta^{(m)} + H^{(m)} (Y - \mu^{(m)})$, con lo cual la solución para $\beta^{(m+1)}$ es:

$$\beta^{(m+1)} = (X^t W^{(m)} X)^{-1} X^t W^{(m)} \mathbf{z}^{(m)}. \quad (13.9)$$

La ecuación (13.9) es válida para cualquier MLG y muestra que la solución de las ecuaciones de máxima verosimilitud (MV) equivale a calcular repetidamente una regresión lineal ponderada de una variable dependiente ajustada $\mathbf{z}$ sobre una matriz X con una matriz de peso W que se modifica en el proceso iterativo. Es importante enfatizar que la ecuación iterativa (13.9) no depende del parámetro de dispersión ϕ .

Cuando las variables explicativas son de carácter cuantitativo, se puede utilizar la metodología de superficies de respuesta con el fin de optimizar μ . Este procedimiento se presenta en la siguiente sección.

13.4. Bondad de ajuste de un MLG

Una forma de examinar la bondad de ajuste de un MLG es compararlo con el modelo saturado, es decir, contrastarlo con el MLG que coincide con el modelo ajustado en la distribución de la variable respuesta y en la función de enlace, pero se diferencia de este en que estima el número máximo de parámetros posible. Para realizar tal comparación, se utiliza la deviance definida como:

$$d_{\mu} = 2 \left(\ell(\hat{\mu}_{\text{máx}}, Y) - \ell(\hat{\mu}, Y) \right) = \sum_{i=1}^n 2 \left[\ell_i(\hat{\mu}_{i(\text{max})}, y_i) - \ell_i(\hat{\mu}_i, y_i) \right],$$

donde $\hat{\mu}_{\text{máx}}$ es el estimador del vector de máxima verosimilitud correspondiente al modelo maximal o saturado, $\hat{\mu}$ es el estimador del vector de máxima verosimilitud para el modelo de interés (modelo ajustado) y ℓ es el logaritmo de la función de verosimilitud del modelo.

Obviamente, $\ell(\hat{\mu}_{\text{máx}}, Y)$ debe ser mayor que $\ell(\hat{\mu}, Y)$, ya que suministra la mejor descripción de los datos. Cabe mencionar, además, que d es un valor particular de la variable aleatoria

$$D_{\mu} = 2(\ell(\hat{\mu}_{\text{máx}}, Y) - \ell(\hat{\mu}, Y));$$

y D converge en distribución a una variable aleatoria con distribución Ji-cuadrado con $n - p$ grados de libertad bajo condiciones de regularidad (McCullagh y Nelder 1989, Dobson 2002, Dobson 2008), siendo p el número de parámetros a estimar con el modelo ajustado.

Observe que

$$d_{\mu} = \sum_{i=1}^n (r_i^d)^2,$$

donde

$$r_i^d = \text{sign}(y_i - \hat{\mu}_i) \left\{ 2 \left[\ell_i(\hat{\mu}_{i(\text{max})}, y_i) - \ell_i(\hat{\mu}_i, y_i) \right] \right\}^{1/2}.$$

Note que la i -ésima observación contribuye una cantidad de $(r_i^d)^2$ a la deviance d_{μ} , y, por consiguiente, una observación con un r_i^d grande en valor absoluto se puede ver como un residual extremo.

También es posible definir los residuales estandarizados o de Pearson:

$$r_i^P = \frac{y_i - \hat{\mu}_i}{\sqrt{\hat{v} \hat{a} r(y_i)}}, \quad i = 1, \dots, n,$$

donde $\hat{\mu}_i = g^{-1}(x_i^t \beta)$. Un gráfico de estos residuales *versus* el índice i de las observaciones debería mostrar patrones no detectables. Una tendencia

detectable en el gráfico de r_i contra $\hat{\eta}_i$ puede sugerir una mala especificación en la función de enlace (McCullagh y Nelder 1989).

De esta manera, si el modelo ajusta bien, es de esperarse que la suma de cuadrados de los residuales de Pearson sea aproximadamente igual a los grados de libertad del modelo (Dobson 2002), es decir,

$$\sum_{i=1}^n (r_i^P)^2 \approx n - p.$$

Por ejemplo, el estadístico d_π de bondad de ajuste para el modelo Binomial es:

$$\begin{aligned} d_\pi &= 2 [\ell(\hat{\pi}_{max}, \mathbf{y}) - \ell(\hat{\pi}, \mathbf{y})] \\ &= 2 \sum_{i=1}^N \left[y_i \ln \left(\frac{y_i}{\hat{y}_i} \right) + (n_i - y_i) \ln \left(\frac{n_i - y_i}{n_i - \hat{y}_i} \right) \right], \end{aligned}$$

donde $\hat{y}_i = n_i \hat{\pi}_i$. Se obtiene derivando parcialmente la función de log-verosimilitud de la función binomial, correspondiente al modelo saturado con respecto a π_i e igualando a cero.

Por otro lado, el valor de d_λ para el modelo de regresión de Poisson está dado por

$$d_\lambda = 2[\ell(\hat{\lambda}_{max}, \mathbf{y}) - \ell(\hat{\lambda}, \mathbf{y})] = 2 \sum_{i=1}^N \left[y_i \ln \left(\frac{y_i}{\hat{y}_i} \right) - (y_i - \hat{y}_i) \right],$$

donde la expresión $\hat{y}_i = \hat{\lambda}_i$, es el resultado de derivar parcialmente la función de log-verosimilitud de la función Poisson con respecto a λ_i e igualando a cero.

13.5. MLG con sobredispersión o subdispersión

En el MLG se detecta *subdispersión* si la deviance calculada es significativamente menor que los grados de libertad del modelo, esto es, si se tiene

$$d_\mu < n - p.$$

Así mismo, se manifiesta sobredispersión si la deviance calculada es significativamente mayor que los grados de libertad del modelo, es decir, si se cumple

$$d_\mu > n - p.$$

Una forma de incorporar la sobredispersión o subdispersión al modelo es incluir parámetros adicionales en la variación del mismo. Sin pérdida de generalidad, se considerará a continuación la forma general que asume la varianza del modelo binomial con enlace logit cuando se incluye la sobredispersión o la subdispersión.

13.5.1. Modelo binomial con sobredispersión o subdispersión

En un MLG binomial con enlace logit, al incluir parámetros adicionales en la varianza se obtiene una forma general dada por (Hinde y Demétrio 1998):

$$Var(Y_i) = m_i \pi_i (1 - \pi_i) \left[1 + \phi (m_i - 1)^{\delta_1} \{ \pi_i (1 - \pi_i) \}^{\delta_2} \right], \quad i = 1, 2, \dots, n,$$

donde se observa lo siguiente:

- Si $\phi = 0$, no hay problemas de sobredispersión o subdispersión.
- Si $\delta_1 = \delta_2 = 0$ y $(\phi > 0)$, hay sobredispersión constante determinada por ϕ .
- Si $\delta_1 = \delta_2 = 0$ y $(\phi < 0)$, hay subdispersión constante determinada por ϕ .

En el caso particular $\delta_1 = 1$ y $\delta_2 = 0$, la función de varianza es denominada beta-binomial. Si además se asume que existen n variables aleatorias P_i , $i = 1, 2, \dots, n$, tales que $Y_i | P_i \sim Bin(m_i, P_i)$, $P_i \sim Beta(\alpha_i, \beta_i)$, con $\alpha_i + \beta_i$ constante, $E(P_i) = \pi_i$, $Var(P_i) = \phi \pi_i (1 - \pi_i)$, $E(Y_i) = m_i \pi_i$ y $Var(Y_i) = m_i \pi_i (1 - \pi_i) [1 + \phi (m_i - 1)]$, se dice que las Y_i tienen distribución beta-binomial (Hinde y Demétrio 1998).

13.5.2. Métodos de estimación en un MLG logit con sobredispersión y subdispersión

En un modelo de sobredispersión o subdispersión, la estimación de los parámetros teóricamente se puede realizar por máxima verosimilitud, pero los cálculos son más engorrosos a medida que la función de varianza es más compleja. En la práctica, es más conveniente utilizar otros métodos que proveen buenas aproximaciones vía métodos numéricos y cuyos cálculos no son complicados.

Los métodos de estimación de los parámetros se utilizan de acuerdo con la situación específica que se tenga, tal como se presenta a continuación.

Máxima verosimilitud. La función de verosimilitud, $L(\boldsymbol{\beta}, Y)$, de un conjunto de variables aleatorias Y_i , $i = 1, 2, \dots, n$ independientes e idénticamente distribuidas corresponde con su función conjunta de densidad, es decir,

$$L(\boldsymbol{\beta}, Y) = \prod_{i=1}^n f_{Y_i}(Y_i).$$

Para encontrar los estimadores máximo verosímiles de los parámetros, se hallan los máximos de la función de verosimilitud respecto a los parámetros. Cuando la sobredispersión o la subdispersión son constantes, el vector de parámetros $\boldsymbol{\beta}$ se estima mediante mínimos cuadrados y el parámetro de sobredispersión o subdispersión con

$$\hat{\phi} = \frac{1}{n-p} \sum_{i=1}^n \frac{(y_i - m_i \hat{\pi}_i)^2}{m_i \hat{\pi}_i (1 - \hat{\pi}_i)}.$$

Los errores estándar de $\hat{\boldsymbol{\beta}}$ se multiplican por $\sqrt{\hat{\phi}}$.

Cuasi verosimilitud extendida. Los modelos de sobredispersión o subdispersión más complejos pueden ser descritos generalmente con una varianza de la forma

$$Var(Y_i) = \phi_i(\gamma)V(\mu_i, \lambda),$$

donde $V(\mu_i, \lambda) = d(\mu_i, \lambda)/d\theta_i$ se denomina la función de varianza y depende únicamente de μ_i y λ . Estos modelos complejos tienen en la varianza una forma funcional que depende de la media y de los parámetros agregados λ y γ .

La estimación de $\boldsymbol{\beta}$ no varía respecto al modelo tradicional. Se estiman los parámetros adicionales de varianza maximizando la función de cuasi verosimilitud extendida, presentada a continuación, respecto a λ y γ .

$$Q^+ = -\frac{1}{2} \sum_{i=1}^n \left(\frac{d(\mu_i, Y_i)}{\phi} + \ln(2\pi \phi V(Y_i)) \right).$$

Pseudo verosimilitud. Se utiliza también en modelos de sobredispersión o subdispersión complejos donde la varianza está dada por

$$Var(Y_i) = \phi_i(\gamma)V(\mu_i, \lambda).$$

En este método, las estimaciones de $\boldsymbol{\beta}$ son obtenidas por mínimos cuadrados generalizados y los parámetros adicionales de la varianza

(λ y γ) se basan en la maximización de

$$l_1 = -\frac{1}{2} \sum_{i=1}^n \left(\frac{(Y_i - \mu_i)^2}{\phi_i V(Y_i)} + \ln(2\pi \phi_i) V(Y_i) \right).$$

13.6. Hipótesis sobre el vector de parámetros

Se puede probar que la distribución muestral del estimador máximo verosímil, $\hat{\beta}$, es asintóticamente normal con media y varianza, β y $\mathcal{F}^{-1}$, respectivamente (McCullagh y Nelder 1989, Dobson 2008).

Para hacer inferencias sobre el vector de parámetros β , se plantea la siguiente hipótesis:

$$H_0 : \beta = \mathbf{0} \quad \text{contra} \quad H_1 : \beta \neq \mathbf{0},$$

la cual se puede contrastar mediante el uso del estadístico de prueba $W = (\hat{\beta} - \beta)^t \mathcal{F}(\hat{\beta} - \beta)$, llamado *estadístico de Wald*. El estadístico W tiene una distribución χ_p^2 , en la que $s = 2k + 1$ es el número total de parámetros a estimar. Se rechaza H_0 si $W > \chi_{(p, \alpha)}^2$.

La hipótesis sobre los parámetros individuales, $H_0 : \beta_r = 0$ contra $H_1 : \beta_r \neq 0$ donde $r = 1, \dots, k$, se juzga con el estadístico $W = \left(\frac{\hat{\beta}_r}{s_{\hat{\beta}_r}} \right)^2$. La hipótesis nula se rechaza si $W > \chi_{(1, \alpha)}^2$.

En la siguiente sección, como complemento de la parte inferencial de los modelos, se presentan los intervalos de confianza para los parámetros y las predicciones.

13.7. Intervalos de confianza de los parámetros y de predicción

El cálculo del intervalo de confianza para los parámetros estimados β_r al $(1 - \alpha) \%$ es:

$$\left(\hat{\beta}_r - z_{(1-\alpha/2)} s_{\hat{\beta}_r}, \hat{\beta}_r + z_{(1-\alpha/2)} s_{\hat{\beta}_r} \right),$$

donde $z_{(1-\alpha/2)}$ es el percentil $(1 - \alpha/2)$ de la distribución normal estándar, $s_{\hat{\beta}_r}$ es el error estándar del parámetro $\hat{\beta}_r$, el cual se calcula como la raíz cuadrada del r -ésimo elemento de la diagonal de la inversa de la matriz $\mathcal{F}$ de Fisher.

En MLG los intervalos de confianza de predicción se basan (asintóticamente) en la estadística de Wald. Por consiguiente, dichos intervalos son

útiles para tamaños de muestras grandes, pero en diseños experimentales usualmente se tienen tamaños de muestra pequeños. Por consiguiente, para usar intervalos de confianza con la finalidad de comparar el desempeño de los modelos, es esencial evaluar los intervalos asintóticos en términos de la cobertura y precisión para muestras pequeñas (Lewis et al. 2001a).

Por lo anterior, se utiliza intervalos de confianza para la respuesta de tipo Wald con enlace canónico. El enlace canónico es la función que iguala el parámetro natural de la familia exponencial al predictor lineal. En los modelos binomial y Poisson, los parámetros naturales son $\ln\left(\frac{\pi_i}{1-\pi_i}\right)$ y $\ln \lambda_i$, respectivamente.

Los intervalos de confianza en los MLG cuando se aplican a datos de diseños experimentales, incluso para muestras pequeñas, tienen longitud mínima en comparación con el uso de métodos tradicionales (Lewis et al. 2001a).

A continuación se presentan los intervalos de confianza para la respuesta media con enlace canónico, propuestos por Lewis et al. (2001a), en problemas con distribuciones binomial y Poisson, respectivamente:

- Caso binomial

$$\hat{\pi}_i \pm z_{(1-\alpha/2)} \hat{\pi}_i (1 - \hat{\pi}_i) \sqrt{\mathbf{x}_i (\mathbf{X}^t \mathbf{V} \mathbf{X})^{-1} \mathbf{x}_i^t},$$

donde $\hat{\pi}_i = \frac{\exp(\mathbf{x}_i^t \boldsymbol{\beta})}{1 + \exp(\mathbf{x}_i^t \boldsymbol{\beta})}$ y $\mathbf{V} = \text{diag}(\text{Var}(Y_i))$ es una matriz diagonal en la cual los elementos de la diagonal principal son las varianzas de la variable respuesta.

- Caso Poisson

$$\hat{\lambda}_i \pm z_{(1-\alpha/2)} \hat{\lambda}_i \sqrt{\mathbf{x}_i (\mathbf{X}^t \mathbf{V} \mathbf{X})^{-1} \mathbf{x}_i^t},$$

donde $\hat{\lambda}_i = \exp(\mathbf{x}_i^t \boldsymbol{\beta})$ y $\mathbf{V}$ tiene una estructura similar al caso binomial.

13.8. Bondad de ajuste y medidas de diagnóstico

Para llevar a cabo un análisis de diagnóstico con la finalidad de comprobar la bondad de ajuste del modelo ajustado, una medida global de la variación explicada se obtiene calculando el pseudo R_1^2 , el cual se calcula como:

$$R_1^2 = r^2(\hat{\boldsymbol{\eta}}, g(\mathbf{y})), \quad 0 \leq R_1^2 \leq 1, \quad (13.10)$$

donde $r(\hat{\boldsymbol{\eta}}, g(\mathbf{y}))$ es el coeficiente de correlación entre $\hat{\boldsymbol{\eta}}$ y $g(\mathbf{y})$. Cuando $R_1^2 \approx 1$, hay un acuerdo perfecto entre $\hat{\boldsymbol{\eta}}$ y $g(\mathbf{y})$, por lo tanto entre $\hat{\boldsymbol{\mu}}$ y $\mathbf{y}$.

Otra medida de bondad de ajuste que tiene un papel análogo a la suma de cuadrados residual de los modelos lineales generales clásicos es:

$$R_2^2 = 1 - \frac{\sum_{i=1}^n (\eta_i - \hat{\eta}_i)^2 / (n - k)}{\sum_{i=1}^n (\eta_i - \bar{\eta})^2 / (n - 1)}, \quad (13.11)$$

donde $\eta_i = \mathbf{x}_i^t \boldsymbol{\beta}$ y $\hat{\eta}_i = \mathbf{x}_i^t \hat{\boldsymbol{\beta}}$, es decir, es el valor ajustado una vez son estimados los parámetros $\boldsymbol{\beta}$.

Ejemplo 13.1. *Este es un diseño factorial fraccionado 2^{4-1} dirigido a procesos de sellado de parabrisas en la industria. Durante la operación de sellado aparecen daños en el producto, así, la variable respuesta es el número de partes buenas producidas en 1000 unidades; es lógico asumir que la distribución binomial es un modelo razonable. La tabla 13.3 contiene la matriz diseño y la variable respuesta para este experimento (Lewis et al. 2001b).*

Tabla 13.3: Número de partes buenas producidas

Corrida	x_1	x_2	x_3	x_4	Partes buenas
1	1	1	1	1	338
2	1	-1	1	1	350
3	1	-1	-1	-1	647
4	1	1	-1	-1	826
5	-1	1	1	-1	917
6	-1	-1	1	-1	953
7	-1	-1	-1	-1	972
8	-1	1	-1	1	977

En primer lugar, se realizó un ajuste utilizando varias funciones de enlace como se puede ver en la tabla 13.4. En esta tabla, se presentan la deviance y los pseudo R_1^2 y R_2^2 , aunque estos dos últimos no son de mucha utilidad, ya que no son comparables cuando se tienen diferentes funciones de enlace. De acuerdo con la tabla 13.4, el enlace logit es la función de enlace que mejor funciona para este caso en cuanto a su relación con las variables explicativas (x_1 , x_2 , x_3 y x_4), ya que tiene la deviance (0.28) mas baja.

El modelo basado en la metodología propuesta es:

$$\hat{\pi}_i = \frac{1}{1 + e^{-(1.701 - 1.483x_{1i} + 0.069x_{2i} - 0.667x_{3i} - 0.196x_{4i} + 0.154x_{1i}x_{2i} - 0.244x_{2i}x_{3i})}}.$$

De acuerdo con los pseudo $R_1^2 = 0.9999$ y $R_2^2 = 0.9998$, las variables x_1 , x_2 , x_3 y x_4 están explicando cerca de un 99.9% al número de partes buenas producidas.

Tabla 13.4: Criterios de ajuste empleando algunas funciones de enlace en el número de partes buenas

Enlace	Deviance	Pseudo- R^2_1	Pseudo- R^2_2
probit	1.65	0.9997	0.9982
logit	0.28	0.9999	0.9998
cloglog	4.86	0.9988	0.9919
Cauchit	1.37	0.9999	0.9995
loglog	11.64	0.9952	0.9662

En segundo lugar, se ajustó un modelo cuadrático, que se presenta en la tabla 13.5, haciendo uso del enlace logit. En esta tabla se muestran los resultados del estadístico de Wald junto con los intervalos de confianza para los parámetros incluidos en el modelo ajustado, en la que se puede observar que el único efecto no significativo al 5% es x_2 (valor $p = 0.12$), pero debido a la jerarquía de las interacciones dobles que involucran este efecto se deja este. Además, en esta tabla se presentan los intervalos de confianza para cada uno de los parámetros involucrados en el modelo ajustado a partir de los cuales se concluye lo mismo que con el valor p .

Tabla 13.5: Coeficientes estimados al relacionar el número de partes buenas producidas en 1000 unidades con las variables x_1 , x_2 , x_3 y x_4

Efecto	Coeficiente estimado	Error estándar	Wald	valor p	Intervalo de confianza
Intercepto	1.701	0.046	1364.85	0.00	(1.61, 1.79)
x_1	-1.483	0.046	1050.92	0.00	(-1.57, -1.39)
x_2	0.069	0.044	2.48	0.12	(-0.02, 0.17)
x_3	-0.667	0.047	205.63	0.00	(-0.76, -0.59)
x_4	-0.196	0.046	17.73	0.00	(-0.29, -0.11)
x_1x_2	0.154	0.044	12.58	0.00	(0.08, 0.24)
x_2x_3	-0.244	0.033	55.31	0.00	(-0.31, -0.18)

Una manera de medir la eficiencia del modelo es en términos de la amplitud del intervalo de confianza de predicción, obviamente entre más pequeño mejor será la calidad de las estimaciones para la respuesta media. En la tabla 13.6, se presentan algunos intervalos de confianza para las predicciones de la probabilidad de encontrar partes buenas, así como sus amplitudes.

Por último, se verifica la adecuación del modelo sobre sus residuales, para lo cual se emplean los de Pearson y deviance. Estos se presentan en la figura 13.1, en la que se observa que no hay presencia de observaciones atípicas y que hay un buen ajuste del modelo propuesto.

Tabla 13.6: Intervalos de confianza para las predicciones de la probabilidad de encontrar partes buenas producidas en 1000 unidades

Observación	$\hat{y}_i$	π_i	$\hat{\pi}_i$	IC($\hat{\pi}_i$)	Cobertura
1	339.4	0.339	0.34	(0.31, 0.36)	0.05
2	348.6	0.349	0.35	(0.32, 0.37)	0.05
3	648.4	0.648	0.65	(0.62, 0.67)	0.05
4	824.6	0.825	0.82	(0.81, 0.84)	0.03
5	915.6	0.916	0.92	(0.90, 0.93)	0.03
6	954.4	0.954	0.95	(0.95, 0.96)	0.02
7	970.6	0.971	0.97	(0.97, 0.98)	0.01
8	824.6	0.825	0.82	(0.81, 0.84)	0.01




Figura 13.1: Residuales de Pearson y de deviance para número de partes buenas producidas en 1000 unidades.

Cuando se realiza un experimento factorial de dos niveles, por lo general a la respuesta se le ajusta un modelo de primer orden, pero deberá estarse alerta ante la posibilidad de que el modelo de segundo orden sea en realidad el más apropiado debido a que se puede estar ocultando el verdadero comportamiento sobre la variable respuesta al incluir tan solo dos niveles sobre los factores de interés. Por ello, se debe aumentar el experimento con mediciones en el centro y en los ejes de los diferentes factores; el diseño resultante es llamado *diseño central compuesto*, y es uno de los más importantes que se usa en estudios de optimización de procesos.

Ejemplo 13.2. *Este experimento es un diseño central compuesto rotatable, cuyo objetivo es investigar el número de defectos en obleas en un semiconductor en procesos de manufactura (Lewis et al. 2001b). En este caso, es razonable asumir que la*

variable de interés sigue una distribución de Poisson. La matriz diseño y la variable respuesta para esta aplicación se presentan en la tabla 13.7.

Tabla 13.7: Variables explicativas codificadas y número de defectos en obleas en un proceso de manufactura

Corrida	x_1	x_2	x_3	Observado
1	-1	-1	-1	1
2	1	-1	-1	15
3	-1	1	-1	24
4	1	1	-1	35
5	-1	-1	1	0
6	1	-1	1	13
7	-1	1	1	16
8	1	1	1	13
9	$-\sqrt{3}$	0	0	1
10	$\sqrt{3}$	0	0	17
11	0	$-\sqrt{3}$	0	7
12	0	$\sqrt{3}$	0	43
13	0	0	$-\sqrt{3}$	14
14	0	0	$\sqrt{3}$	3
15	0	0	0	4
16	0	0	0	7
17	0	0	0	8
18	0	0	0	6

El modelo de regresión ajustado es bueno, ya que el estadístico d es igual a 13.82 que es menor a una Ji-cuadrado, con 12 grados de libertad (21.03), y a los pseudos $R_1^2 = 0.929$ y $R_2^2 = 0.896$, con lo cual el modelo cuadrático está explicando cerca del 90 % al número de defectos en obleas. Además, según los resultados de la tabla 13.8, todos los parámetros asociados con las variables explicativas son significativas al 5%.

Tabla 13.8: Importancia de los parámetros involucrados en el modelo (13.12)

Efecto	Coficiente estimado	Error estándar	Wald	valor p	Intervalo de confianza
Intercepto	1.929	0.114	288.01	0.00	(1.71, 2.15)
x_1	0.611	0.098	39.07	0.00	(0.42, 0.80)
x_2	0.703	0.100	49.48	0.00	(0.51, 0.90)
x_3	-0.353	0.084	17.75	0.00	(-0.52, -0.19)
x_1x_2	-0.521	0.120	18.72	0.00	(-0.76, -0.29)
x_2^2	0.248	0.076	10.73	0.00	(0.10, 0.40)

El modelo ajustado siguiendo la metodología propuesta, dejando solamente los efectos estadísticamente significativos y utilizando la función de enlace $\ln$, es:

$$\hat{\lambda} = e^{1.929+0.611x_1+0.703x_2-0.353x_3-0.521x_1x_2+0.248x_2^2}. \quad (13.12)$$

Al igual que en el experimento del parabrisas, una manera de medir la eficiencia del modelo es en términos de la amplitud del intervalo de confianza de predicción. Estos intervalos, para la predicción de la respuesta media, se exponen en la tabla 13.9.

Tabla 13.9: Intervalos de confianza para las predicciones del número de partes defectuosas

Observación	$\hat{\lambda}_i$	IC($\hat{\lambda}_i$)	Amplitud
1	2.005	(1.469, 2.541)	1.072
2	19.260	(14.628, 23.892)	9.264
3	23.173	(17.558, 28.788)	11.230
4	27.706	(21.003, 34.409)	13.407
5	0.989	(0.750, 1.229)	0.479
6	9.505	(7.202, 11.808)	4.606
7	11.436	(8.685, 14.186)	5.501
8	13.673	(10.017, 17.329)	7.313
9	2.392	(1.773, 3.012)	1.238
10	19.812	(14.685, 24.940)	10.255
11	4.278	(3.383, 5.173)	1.790
12	48.807	(38.595, 59.019)	20.424
13	12.691	(9.234, 16.148)	6.913
14	3.735	(2.718, 4.752)	2.035
15	6.885	(6.883, 6.886)	0.003
16	6.885	(6.883, 6.886)	0.003
17	6.885	(6.883, 6.886)	0.003
18	6.885	(6.883, 6.886)	0.003

En la figura 13.2, se verifican algunos supuestos sobre los residuales del modelo ajustado, para lo cual se emplean los de Pearson y deviance, en los que no se encuentra ninguna observación atípica y se evidencia un buen ajuste del modelo propuesto.

En los gráficos de la figura 13.3, se muestra el comportamiento del número de defectos en obleas en un semiconductor y sus curvas de nivel en los diferentes niveles de la variable x_3 ($-1, 0, 1$).




Figura 13.2: Residuales de Pearson y de deviance para defectos en obleas en un semiconductor.




Figura 13.3: Superficies de respuestas y gráficos de contorno para los defectos en obleas en un semiconductor.

13.9. Implementación en SAS

A partir de los datos de los ejemplos presentados a lo largo del capítulo, se presentan a continuación los programas en el paquete estadístico SAS a través

del cual se obtuvieron los diversos resultados expuestos en los ejemplos: [13.1](#) y [13.2](#).

```

/* EJEMPLO 13.1 */
DATA EJEMPLO131;
INPUT X1 X2 X3 X4 PBUENAS N @@;
CARDS;
1 1 1 1 338 1000
1 -1 1 1 350 1000
1 -1 -1 -1 647 1000
1 1 -1 -1 826 1000
-1 1 1 -1 917 1000
-1 -1 1 -1 953 1000
-1 -1 -1 -1 972 1000
-1 1 -1 1 977 1000
;

/*****
/* GRÁFICOS SUPERFICIES DE RESPUESTA Y CURVAS DE NIVEL */
*****/

TITLE H=1.3 F=SWISS C=BLACK 'SUPERFICIE DE RESPUESTA ';

PROC G3GRID DATA=EJEMPLO131 OUT=CUAD;
GRID X1*X2=PBUENAS/ AXIS1=-1 TO 1 BY 0.2 AXIS2=-1 TO 1 BY 0.3
SPLINE;
RUN;

PROC G3D DATA=CUAD;
PLOT X1*X2=PBUENAS/ YTICKNUM=5 XTICKNUM=6 CTOP=RED;

TITLE H=1.3 F=SWISS C=BLACK ' CURVAS DE NIVEL ';

PROC GCONTOUR DATA=CUAD;
PLOT X1*X2=PBUENAS/YTICKNUM=8 XTICKNUM=8
LEVELS=340 450 550 650 750 850 970 LLEVELS=1 2 3 4 5 6 7 8 NOLEGEND AUTOLABEL;
RUN;

/* MODELOS CON DIFERENTES FUNCIONES DE ENLACE */

PROC GENMOD DATA=EJEMPLO131;
MODEL PBUENAS/N=X1 X2 X3 X4 X1*X2 X2*X3/DIST=BIN LINK=PROBIT LRCI;

PROC GENMOD DATA=EJEMPLO131;
MODEL PBUENAS/N=X1 X2 X3 X4 X1*X2 X2*X3/DIST=BIN LINK=LOGIT R RESIDUALS PRED
PREDICTED LRCI;

PROC GENMOD DATA=EJEMPLO131;
MODEL PBUENAS/N=X1 X2 X3 X4 X1*X2 X2*X3/DIST=BIN LINK=CLOGLOG LRCI;

```

```

PROC GENMOD DATA=EJEMPL0131;
MODEL PBUENAS/N=X1 X2 X3 X4 X1*X2 X2*X3/DIST=BIN LINK=LOG LRCI;
RUN;

/* EJEMPL013.2 */
DATA EJEMPL0132;
INPUT X1 X2 X3 OBS @@;
CARDS;
-1 -1 -1 1
1 -1 -1 15
-1 1 -1 24
1 1 -1 35
-1 -1 1 0
1 -1 1 13
-1 1 1 16
1 1 1 13
-1.73 0 0 1
1.73 0 0 17
0 -1.73 0 7
0 1.73 0 43
0 0 -1.73 14
0 0 1.73 3
0 0 0 4
0 0 0 7
0 0 0 8
0 0 0 6
;

/*****
/* GRÁFICOS SUPERFICIES DE RESPUESTA Y CURVAS DE NIVEL */
*****/

TITLE H=1.3 F=SWISS C=BLACK 'SUPERFICIE DE RESPUESTA ';

PROC G3GRID DATA=EJEMPL0132 OUT=CUAD;
GRID X1*X2=OBS/ AXIS1=-1.74 TO 1.94 BY 0.3 AXIS2=-1.74 TO 1.94 BY 0.3
SPLINE;
RUN;

PROC G3D DATA=CUAD;
PLOT X1*X2=OBS/ YTICKNUM=5 XTICKNUM=6 CTOP=RED;

TITLE H=1.3 F=SWISS C=BLACK ' CURVAS DE NIVEL ';

PROC GCONTOUR DATA=CUAD;
PLOT X1*X2=OBS/YTICKNUM=8 XTICKNUM=8
LEVELS=1 6 13 18 25 31 38 LLEVELS=1 2 3 4 5 6 7 8 NOLEGEND AUTOLABEL;
RUN;

```

```
/* MODELO AJUSTADO */
PROC GENMOD DATA=EJEMPLO132;
MODEL OBS=X1 X2 X3 X1*X2 X2*X2/DIST=POISSON LINK=LOG R RESIDUALS PRED
PREDICTED LRCI;
RUN;
```

13.10. Implementación en R

A partir de los datos de los ejemplos [13.1](#) y [13.2](#), se presenta a continuación el programa en el software estadístico R.

```
#####
## Ejemplo 13.1 ##
#####

p.buenas <- c(338,350,647,826,917,953,972,977)
p.malas <- 1000-p.buenas
x1 <- c(rep(1,4),rep(-1,4))
x2 <- c(1,-1,-1,1,1,-1,-1,1)
x3 <- c(1,1,-1,-1,1,1,-1,-1)
x4 <- c(1,1,-1,-1,-1,-1,1,1)
ejemplo13.1 <- data.frame(p.buenas,p.malas,x1,x2,x3,x4)

# enlace probit
glm.parab.probit <- glm(cbind(p.buenas,p.malas)~x1+x2+x3+x4+x1*x2+x2*x3,
family = binomial(link=probit))
anova(glm.parab.probit)
summary(glm.parab.probit)

# Pseudo R^2 probit
pseudo.R1.probit <- cor(glm.parab.probit$fitt*1000,p.buenas)^2
pseudo.R1.probit
pseudo.R2.probit <- 1-(sum((glm.parab.probit$fitt-p.buenas/1000)^2)/(8-7))/
(sum((p.buenas/1000-mean(p.buenas/1000))^2)/(8-1))
pseudo.R2.probit

# enlace logit
glm.parab.logit <- glm(cbind(p.buenas,p.malas)~x1+x2+x3+x4+x1*x2+x2*x3,
family = binomial(link=logit))
anova(glm.parab.logit)
summary(glm.parab.logit)
cor(glm.parab.logit$fitt*1000,p.buenas)^2
# Pseudo R^2 logit
pseudo.R1.logit <- cor(glm.parab.logit$fitt*1000,p.buenas)^2
pseudo.R1.logit
pseudo.R2.logit <- 1-(sum((glm.parab.logit$fitt-p.buenas/1000)^2)/(8-7))/
(sum((p.buenas/1000-mean(p.buenas/1000))^2)/(8-1))
```

```
pseudo.R2.logit
```

```
# enlace cloglog
glm.parab.cloglog <- glm(cbind(p.buenas,p.malas)~x1+x2+x3+x4+x1*x2+x2*x3,
family = binomial(link=cloglog))
anova(glm.parab.cloglog)
summary(glm.parab.cloglog)
cor(glm.parab.cloglog$fitt*1000,p.buenas)^2

# Pseudo R^2 cloglog
pseudo.R1.cloglog <- cor(glm.parab.cloglog$fitt*1000,p.buenas)^2
pseudo.R1.cloglog
pseudo.R2.cloglog <- 1-(sum((glm.parab.cloglog$fitt-p.buenas/1000)^2)/(8-7))/
(sum((p.buenas/1000-mean(p.buenas/1000))^2)/(8-1))
pseudo.R2.cloglog
```

```
# enlace log-log
glm.parab.log <- glm(cbind(p.buenas, p.malas)~x1+x2+x3+x4+x1*x2+x2*x3,
family = binomial(link=log))
anova(glm.parab.log)
summary(glm.parab.log)
cor(glm.parab.log$fitt*1000,p.buenas)^2
```

```
# Pseudo R^2 log-log
pseudo.R1.log <- cor(glm.parab.log$fitt*1000,p.buenas)^2
pseudo.R1.log
pseudo.R2.log <- 1-(sum((glm.parab.log$fitt-p.buenas/1000)^2)/(8-7))/
(sum((p.buenas/1000-mean(p.buenas/1000))^2)/(8-1))
pseudo.R2.log
```

```
# enlace Cauchit
glm.parab.cauchit <- glm(cbind(p.buenas, p.malas)~x1+x2+x3+x4+x1*x2+x2*x3,
family = binomial(link=cauchit))
anova(glm.parab.cauchit)
summary(glm.parab.cauchit)
cor(glm.parab.cauchit$fitt*1000,p.buenas)^2
```

```
# Pseudo R^2 Cauchit
pseudo.R1.cauchit <- cor(glm.parab.cauchit$fitt*1000,p.buenas)^2
pseudo.R1.cauchit
pseudo.R2.cauchit <- 1-(sum((glm.parab.cauchit$fitt-p.buenas/1000)^2)/(8-7))/
(sum((p.buenas/1000-mean(p.buenas/1000))^2)/(8-1))
pseudo.R2.cauchit
```

```
#####
# VALIDACIÓN DE SUPUESTOS GRÁFICAMENTE #
#####
par(mfrow = c(2,2))
plot(glm.parab.logit$fitted,p.buenas)
```



```

E1 <- residuals(glm.parab.logit, type="pearson")
F1 <- predict(glm.parab.logit, type="response")
G1 <- residuals(glm.parab.logit, type="deviance")

plot(E1)
plot(F1)
plot(G1)

# Residuales de Pearson

library(ggplot2)
library(digest)
library(labeling)
library(gridExtra)

p1 <- ggplot(data=NULL,aes(x=F1,y=E1))+xlab('Proporción de partes buenas')+
ylab('Residuales de Pearson')+stat_smooth(aes(x=F1,y=E1),method="glm")+
geom_jitter(size=0.5,position=position_jitter(width=0.05))

#Véase también si hay patrones para nuestras variables explicativas:

p2 <- ggplot(data=ejemplo13.1,aes(factor(x1),y=E1))+ylab("Residuales
de Pearson")+xlab("x1")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

p3 <- ggplot(data=ejemplo13.1,aes(factor(x2),y=E1))+ylab("Residuales
de Pearson")+xlab("x2")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

p4 <- ggplot(data=ejemplo13.1,aes(factor(x3),y=E1))+ylab("Residuales
de Pearson")+xlab("x3")+stat_boxplot()+ geom_hline(yintercept=0,colour=2)

p5 <- ggplot(data=ejemplo13.1,aes(factor(x4),y=E1))+ylab("Residuales
de Pearson")+xlab("x4")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

# Residuales de deviance

d1 <- ggplot(data=NULL,aes(x=F1,y=G1))+xlab('Proporción de partes buenas')+
ylab('Residuales de deviance')+stat_smooth(aes(x=F1,y=G1),method="glm")+
geom_jitter(size=0.5,position=position_jitter(width=0.05))

#Véase también si hay patrones para nuestras variables explicativas:

d2 <- ggplot(data=ejemplo13.1,aes(factor(x1),y=G1))+ylab("Residuales
de deviance")+xlab("x1")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

d3 <- ggplot(data=ejemplo13.1,aes(factor(x2),y=G1))+ylab("Residuales
de deviance")+xlab("x2")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

d4 <- ggplot(data=ejemplo13.1,aes(factor(x3),y=G1))+ylab("Residuales
de deviance")+xlab("x3")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

```

```
d5 <- ggplot(data=ejemplo13.1,aes(factor(x4),y=G1))+ylab("Residuales
de deviance")+xlab("x4")+stat_boxplot()+geom_hline(yintercept=0,colour=2)
```

```
grid.arrange(p1,p2,p3,p4,p5,d1,d2,d3,d4,d5,ncol=5) ##Esta función
# permite colocar las 3 figuras juntas
```

```
#####
# Ejemplo 13.2 #
#####
```

```
X1 <- c(-1,1,-1,1,-1,1,-1,1,-1.73,1.73,0,0,0,0,0,0,0)
X2 <- c(-1,-1,1,1,-1,-1,1,1,0,0,-1.73,1.73,0,0,0,0,0)
X3 <- c(-1,-1,-1,-1,1,1,1,1,0,0,0,0,-1.73,1.73,0,0,0)
obleas <- c(1,15,24,35,0,13,16,13,1,17,7,43,14,3,4,7,8,6)
```

```
ejemplo13.2 <- data.frame(obleas, X1, X2, X3)
```

```
# Enlace log
```

```
glm.obleas.log <- glm(obleas~X1+X2+X3+I(X1*X2)+I(X2^2),data=ejemplo13.2,
family = poisson(link=log))
anova(glm.obleas.log)
summary(glm.obleas.log)
```

```
# Pseudo R^2 log
```

```
pseudo.R1.log <- cor(glm.obleas.log$fit,glm.obleas.log$y)^2
pseudo.R1.log
pseudo.R2.log <- 1-(sum((glm.obleas.log$fit-glm.obleas.log$y)^2)/(18-6))/
(sum((glm.obleas.log$y-mean(glm.obleas.log$y))^2)/(18-1))
pseudo.R2.log
```

```
# Enlace identity
```

```
glm.obleas.ide <- glm(obleas~X1+X2+X3+I(X2*X3)+I(X2^2),data=ejemplo13.2,
family = poisson(link=identity))
anova(glm.obleas.ide)
summary(glm.obleas.ide)
```

```
# Pseudo R^2 identity
```

```
pseudo.R1.ide <- cor(glm.obleas.ide$fit,glm.obleas.ide$y)^2
pseudo.R1.ide
pseudo.R2.ide <- 1-(sum((glm.obleas.ide$fit-glm.obleas.ide$y)^2)/(18-6))/
(sum((glm.obleas.ide$y-mean(glm.obleas.ide$y))^2)/(18-1))
pseudo.R2.ide
```

```
# Enlace sqrt
```

```
glm.obleas.sqrt <- glm(obleas~X1+X2+X3+I(X1*X2)+I(X2^2),start=c(2.63,0.86,
1.16,0.000015,-0.52,0.71), data=ejemplo13.2, family = poisson(link=sqrt))
anova(glm.obleas.sqrt)
summary(glm.obleas.sqrt)
```

```

# Pseudo R^2 identity
pseudo.R1.sqrt <- cor(glm.obleas.ide$fit,glm.obleas.ide$y)^2
pseudo.R1.sqrt
pseudo.R2.sqrt <- 1-(sum((glm.obleas.ide$fit-glm.obleas.ide$y)^2)/(18-6))/
(sum((glm.obleas.ide$y-mean(glm.obleas.ide$y))^2)/(18-1))
pseudo.R2.sqrt

#####
### GRÁFICO CON VALORES ESTANDARIZADOS, EJEMPLO DE LAS OBLEAS ###
#####

x1=seq(-1.73,1.73,length.out=50)
x2=seq(-1.73,1.73,length.out=50)
x3=seq(-1.73,1.73,length.out=50)

f1=function(x1,x2){exp(glm.obleas.log$coef[1]+glm.obleas.log$coef[2]*x1+
glm.obleas.log$coef[3]*x2+glm.obleas.log$coef[4]*(-1)+
glm.obleas.log$coef[5]*I(x2^2)+glm.obleas.log$coef[6]*x1*x2)}

f2=function(x1,x2){exp(glm.obleas.log$coef[1]+glm.obleas.log$coef[2]*x1+
glm.obleas.log$coef[3]*x2+glm.obleas.log$coef[4]*(0)+
glm.obleas.log$coef[5]*I(x2^2)+glm.obleas.log$coef[6]*x1*x2)}

f3=function(x1,x2){exp(glm.obleas.log$coef[1]+glm.obleas.log$coef[2]*x1+
glm.obleas.log$coef[3]*x2+glm.obleas.log$coef[4]*(1)+
glm.obleas.log$coef[5]*I(x2^2)+glm.obleas.log$coef[6]*x1*x2)}

z1= outer(x1,x2,f1)
z2= outer(x1,x2,f2)
z3= outer(x1,x2,f3)

par(mfrow = c(2,3))
persp(x1,x2,z1,col=rainbow(50),theta=50,phi=10,ticktype='detailed',
zlab='defectos en obleas',main='x3=-1')
persp(x1,x2,z2,col=rainbow(50),theta=50,phi=10,ticktype='detailed',
zlab='defectos en obleas',main='x3=0')
persp(x1,x2,z3,col=rainbow(50),theta=50,phi=10,ticktype='detailed',
zlab='defectos en obleas',main='x3=1')

image(x1,x2,z1,xlab='x1',ylab='x2')
contour(x1,x2,z1,xlab='x1',ylab='x2',nlev = 15,add=TRUE)

image(x1,x2,z2,xlab='x1',ylab='x2')
contour(x1,x2,z2,xlab='x1',ylab='x2',nlev = 13,add=TRUE)
image(x1,x2,z3,xlab='x1',ylab='x2')
contour(x1,x2,z3,xlab='x1',ylab='x2',nlev = 13,add=TRUE)

# Gráficos en blanco y negro: ver Figura 13.3

```

```

par(mfrow = c(2,3))
contour(x1,x2,z1,xlab='x1',ylab='x2',nlev = 15)
contour(x1,x2,z2,xlab='x1',ylab='x2',nlev = 13)
contour(x1,x2,z3,xlab='x1',ylab='x2',nlev = 13)

#persp(glm.obleas.log,~ X1+X2+X3+I(X1*X2)+I(X2^2),contours="black")

persp(x1,x2,z1,col=gray(1),theta=50,phi=10,ticktype='detailed',
zlab='defectos en obleas',main='x3=-1')
persp(x1,x2,z2,col=gray(1),theta=50,phi=10,ticktype='detailed',
zlab='defectos en obleas',main='x3=0')
persp(x1,x2,z3,col=gray(1),theta=50,phi=10,ticktype='detailed',
zlab='defectos en obleas',main='x3=1')

#####
# VALIDACIÓN DE SUPUESTOS GRAFICAMENTE #
#####
par(mfrow = c(2,2))
plot(glm.obleas.log$fitted,obleas)

E1 <- residuals(glm.obleas.log,type="pearson")
F1 <- predict(glm.obleas.log, type="response")
G1 <- residuals(glm.obleas.log, type="deviance")
plot(E1)
plot(F1)
plot(G1)

# Residuales de Pearson

p1 <- ggplot(data=NULL,aes(x=F1,y=E1))+xlab('Defectos en obleas')+
ylab('Residuales de Pearson')+stat_smooth(aes(x=F1,y=E1),method="glm")+
geom_jitter(size=0.5,position=position_jitter(width=0.05))

#Véase también si hay patrones para nuestras variables explicativas:
p2 <- ggplot(data=ejemplo13.2,aes(factor(X1),y=E1))+ylab("Residuales de
Pearson")+xlab("x1")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

p3 <- ggplot(data=ejemplo13.2,aes(factor(X2), y=E1))+ylab("Residuales de
Pearson")+xlab("x2")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

p4 <- ggplot(data=ejemplo13.2,aes(factor(X3),y=E1))+ylab("Residuales de
Pearson")+xlab("x3")+stat_boxplot()+geom_hline(yintercept=0,colour=2)

# Residuales de deviance

d1 <- ggplot(data=NULL,aes(x=F1,y=G1))+xlab('Defectos en obleas')+
ylab('Residuales de deviance')+stat_smooth(aes(x=F1,y=G1),method="glm")+
geom_jitter(size=0.5,position=position_jitter(width=0.05))

```

#Véase también si hay patrones para nuestras variables explicativas:

```
d2 <- ggplot(data=ejemplo13.2,aes(factor(X1),y=G1))+ylab("Residuales de
deviance")+xlab("x1")+stat_boxplot()+geom_hline(yintercept=0,colour=2)
```

```
d3 <- ggplot(data=ejemplo13.2,aes(factor(X2),y=G1))+ylab("Residuales de
deviance")+xlab("x2")+stat_boxplot()+geom_hline(yintercept=0,colour=2)
```

```
d4 <- ggplot(data=ejemplo13.2,aes(factor(X3),y=G1))+ylab("Residuales de
deviance")+xlab("x3")+stat_boxplot()+geom_hline(yintercept=0,colour=2)
```

```
grid.arrange(p1,p2,p3,p4,d1,d2,d3,d4,ncol=4) ##Esta función permite
# colocar las 3 figuras juntas
```

13.11. Ejercicios

1. Sea Y una variable aleatoria con distribución Poisson truncada con parámetro λ , esto es, con función de densidad de probabilidad dada por:

$$f(y, \lambda) = \frac{e^{-\lambda} \lambda^y}{y!(1 - e^{-\lambda})} = \frac{\lambda^y}{y!(e^\lambda - 1)} I_{\{1,2,\dots\}}, \quad \lambda > 0.$$

- a. Muestre que esta distribución es un miembro de la familia exponencial.
- b. Muestre que:

$$E(Y) = \mu = \frac{\lambda e^\lambda}{e^\lambda - 1} = \frac{\lambda}{1 - e^{-\lambda}} \quad \text{y}$$

$$V(Y) = \frac{\lambda}{1 - e^{-\lambda}} \left(1 - \frac{\lambda e^{-\lambda}}{1 - e^{-\lambda}} \right) = \mu(1 + \lambda - \mu).$$

- c. Muestre que la función generadora de momentos de Y está dada por:

$$M_Y(t) = \frac{\exp(\lambda e^t) - 1}{e^\lambda - 1}.$$

2. Una distribución para explicar el exceso de ceros en datos de conteo es la distribución de Poisson inflacionada de ceros con función de densidad de probabilidad dada por:

$$P(Y = y) = \begin{cases} \omega + (1 - \omega)e^{-\lambda}, & y = 0 \\ \frac{(1 - \omega)e^{-\lambda} \lambda^y}{y!}, & y = 1, 2, \dots \end{cases}$$

Muestre que $E(Y) = (1 - \omega)\lambda = \mu$ y $V(Y) = \mu + \frac{\omega}{1 - \omega} \mu^2$.

3. Considere an variables aleatorias binarias $Y_{11}, \dots, Y_{an}$ con $P(Y_{ij} = 1) = \pi_{ij}$ y $P(Y_{ij} = 0) = 1 - \pi_{ij}$. La función de probabilidad de Y_{ij} puede ser escrita como

$$\pi_{ij}^{y_{ij}} (1 - \pi_{ij})^{1-y_{ij}},$$

donde $y_{ij} = 0$ o 1 .

- Demuestre que esta función de probabilidad pertenece a la familia exponencial.
- Encuentre $E(\sum_{ij} Y_{ij})$ y $V(\sum_{ij} Y_{ij})$ utilizando los resultados presentados en el presente capítulo.
- Suponga, con base en los resultados de los ítems anteriores, que se quiere ajustar un diseño experimental con un solo factor A que tiene a niveles, el cual está dado por:

$$g(\pi_{ij}) = \ln \left(\frac{\pi_{ij}}{1 - \pi_{ij}} \right) = \mu + \tau_i, \quad i = 1, \dots, a, j = 1, \dots, r.$$

Describa cómo es el proceso de estimación de los parámetros μ , τ_i y π_{ij} .

- Encuentre la devianza del modelo propuesto en c.

4. Considere an variables aleatorias tipo Poisson $Y_{11}, \dots, Y_{an}$, con $P(Y_{ij} = y_{ij}) = \frac{\lambda_{ij}^{y_{ij}} e^{-\lambda_{ij}}}{y_{ij}!}$.

- Demuestre que esta función de probabilidad pertenece a la familia exponencial.
- Encuentre $E(\sum_{ij} Y_{ij})$ y $V(\sum_{ij} Y_{ij})$ utilizando los resultados presentados en el presente capítulo.
- Suponga, con base en los resultados de los ítems anteriores, que se quiere ajustar un diseño experimental con un solo factor A que tiene a niveles, el cual está dado por:

$$g(\lambda_{ij}) = \ln(\lambda_{ij}) = \mu + \tau_i, \quad i = 1, \dots, a, j = 1, \dots, r.$$

Describa cómo es el proceso de estimación de los parámetros μ , τ_i y λ_{ij} .

- d. Encuentre la devianza del modelo propuesto en c.
5. Se están comparando tres soluciones de lavado diferentes a fin de estudiar su efectividad para retardar el crecimiento de bacterias en contenedores de leche de 5 galones. Se hacen observaciones en cuatro días, cuyos datos se muestran enseguida.

Solución	Días			
	1	2	3	4
1	13	2	18	39
2	16	24	17	44
3	5	4	10	8

- a. Proponga el modelo para llevar a cabo el análisis de esta información, haga los supuestos apropiados.
- b. Encuentre los parámetros estimados asociados con el modelo propuesto.
- c. Estime el parámetro de sobredispersión o subdispersión y concluya.
- d. Construya el análisis de varianza y concluya sobre la hipótesis de interés.
- e. Realice el análisis de residuales apropiado y concluya.
6. La tabla 13.10 muestra los datos referentes al conteo de partículas de virus para 5 diferentes diluciones. Se usaron 4 repeticiones para las 4 primeras diluciones y 5 repeticiones para la última dilución. El objetivo del experimento era estimar el número de partículas de virus por unidad de volumen.

Tabla 13.10: Números de partículas de virus para 5 diluciones diferentes

Dilución	Conteo				
0,3162	13	14	17	22	
0,1778	9	14	6	14	
0,1000	4	4	3	5	
0,0562	3	2	1	3	
0,0316	2	1	3	2	2

Fuente: Ridout (1990)

- a. Proponga el modelo para llevar a cabo el análisis de esta información. Haga los supuestos apropiados.
 - b. Encuentre los parámetros estimados asociados con el modelo propuesto.
 - c. Estime el parámetro de sobredispersión o subdispersión y concluya.
 - d. Construya el análisis de varianza y concluya sobre la hipótesis de interés.
 - e. Realice el análisis de residuales apropiado y concluya.
7. Los datos en la tabla 13.11 se refieren a un resultado experimental de control de la broca en el tomate con 4 tratamientos.

Tabla 13.11: Números de tomates sanos y con broca

Insecticida	Tomates		Total
	Sanos	Con broca	
Diazinon	1690	115	1805
Phosdrin	1578	73	1651
Sevin	2061	53	2114
Testemunha	1691	224	1915
Total	7020	465	7485

Fuente: Silveira Neto, Nakano, Bardin y Villa Nova (1976)

- a. Proponga el modelo para llevar a cabo el análisis de esta información. Haga los supuestos apropiados.
- b. Encuentre los parámetros estimados asociados con el modelo propuesto.
- c. Estime el parámetro de sobredispersión o subdispersión y concluya.
- d. Construya el análisis de varianza y concluya sobre la hipótesis de interés.
- e. Realice el análisis de residuales apropiado y concluya.

The background of the page is a repeating pattern of small, light gray statistical diagrams. Each diagram consists of a horizontal axis with three points labeled 8, 10, and 20. Above the axis, there are curved lines representing a distribution or confidence interval. Below the axis, the text $\alpha = 0.01$ is written. The diagrams are arranged in a grid-like fashion, slightly offset from each other.

Apéndice *A* Tablas Estadísticas

Tabla A.1: Percentiles de la distribución normal estándar: $P(Z \geq z) = 1 - \Phi(z)$

z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.4960	0.4920	0.4880	0.4840	0.4801	0.4761	0.4721	0.4681	0.4641
0.1	0.4602	0.4562	0.4522	0.4483	0.4443	0.4404	0.4364	0.4325	0.4286	0.4247
0.2	0.4207	0.4168	0.4129	0.4090	0.4052	0.4013	0.3974	0.3936	0.3897	0.3859
0.3	0.3821	0.3783	0.3745	0.3707	0.3669	0.3632	0.3594	0.3557	0.3520	0.3483
0.4	0.3446	0.3409	0.3372	0.3336	0.3300	0.3264	0.3228	0.3192	0.3156	0.3121
0.5	0.3085	0.3050	0.3015	0.2981	0.2946	0.2912	0.2877	0.2843	0.2810	0.2776
0.6	0.2743	0.2709	0.2676	0.2643	0.2611	0.2578	0.2546	0.2514	0.2483	0.2451
0.7	0.2420	0.2389	0.2358	0.2327	0.2296	0.2266	0.2236	0.2206	0.2177	0.2148
0.8	0.2119	0.2090	0.2061	0.2033	0.2005	0.1977	0.1949	0.1922	0.1894	0.1867
0.9	0.1841	0.1814	0.1788	0.1762	0.1736	0.1711	0.1685	0.1660	0.1635	0.1611
1.0	0.1587	0.1562	0.1539	0.1515	0.1492	0.1469	0.1446	0.1423	0.1401	0.1379
1.1	0.1357	0.1335	0.1314	0.1292	0.1271	0.1251	0.1230	0.1210	0.1190	0.1170
1.2	0.1151	0.1131	0.1112	0.1093	0.1075	0.1056	0.1038	0.1020	0.1003	0.0985
1.3	0.0968	0.0951	0.0934	0.0918	0.0901	0.0885	0.0869	0.0853	0.0838	0.0823
1.4	0.0808	0.0793	0.0778	0.0764	0.0749	0.0735	0.0721	0.0708	0.0694	0.0681
1.5	0.0668	0.0655	0.0643	0.0630	0.0618	0.0606	0.0594	0.0582	0.0571	0.0559
1.6	0.0548	0.0537	0.0526	0.0516	0.0505	0.0495	0.0485	0.0475	0.0465	0.0455
1.7	0.0446	0.0436	0.0427	0.0418	0.0409	0.0401	0.0392	0.0384	0.0375	0.0367
1.8	0.0359	0.0351	0.0344	0.0336	0.0329	0.0322	0.0314	0.0307	0.0301	0.0294
1.9	0.0287	0.0281	0.0274	0.0268	0.0262	0.0256	0.0250	0.0244	0.0239	0.0233
2.0	0.0228	0.0222	0.0217	0.0212	0.0207	0.0202	0.0197	0.0192	0.0188	0.0183
2.1	0.0179	0.0174	0.0170	0.0166	0.0162	0.0158	0.0154	0.0150	0.0146	0.0143
2.2	0.0139	0.0136	0.0132	0.0129	0.0125	0.0122	0.0119	0.0116	0.0113	0.0110
2.3	0.0107	0.0104	0.0102	0.0099	0.0096	0.0094	0.0091	0.0089	0.0087	0.0084
2.4	0.0082	0.0080	0.0078	0.0075	0.0073	0.0071	0.0069	0.0068	0.0066	0.0064
2.5	0.0062	0.0060	0.0059	0.0057	0.0055	0.0054	0.0052	0.0051	0.0049	0.0048
2.6	0.0047	0.0045	0.0044	0.0043	0.0041	0.0040	0.0039	0.0038	0.0037	0.0036
2.7	0.0035	0.0034	0.0033	0.0032	0.0031	0.0030	0.0029	0.0028	0.0027	0.0026
2.8	0.0026	0.0025	0.0024	0.0023	0.0023	0.0022	0.0021	0.0021	0.0020	0.0019
2.9	0.0019	0.0018	0.0018	0.0017	0.0016	0.0016	0.0015	0.0015	0.0014	0.0014
3.0	0.0013	0.0013	0.0013	0.0012	0.0012	0.0011	0.0011	0.0011	0.0010	0.0010

Tabla A.2: Cuantiles de la distribución t Student

v	α								
	0.25	0.20	0.15	0.10	0.05	0.025	0,01	0.005	0.0005
1	1.000	1.376	1.963	3.078	6.314	12.706	31.821	63.656	636.578
2	0.816	1.061	1.386	1.886	2.920	4.303	6.965	9.925	31.600
3	0.765	0.978	1.250	1.638	2.353	3.182	4.541	5.841	12.924
4	0.741	0.941	1.190	1.533	2.132	2.776	3.747	4.604	8.610
5	0.727	0.920	1,156	1.476	2.015	2.571	3.365	4.032	6.869
6	0.718	0.906	1.134	1.440	1.943	2.447	3.143	3.707	5.959
7	0.711	0.896	1.119	1.415	1.895	2.365	2.998	3.499	5.408
8	0.706	0.889	1.108	1.397	1.860	2.306	2.896	3.355	5.041
9	0.703	0.883	1.100	1.383	1.833	2.262	2.821	3.250	4.781
10	0.700	0.879	1.093	1.372	1.812	2.228	2.764	3.169	4.587
11	0.697	0.876	1.088	1.363	1.796	2.201	2.718	3.106	4.437
12	0.695	0.873	1.083	1.356	1.782	2.179	2.681	3.055	4.318
13	0.694	0.870	1.079	1.350	1.771	2.160	2.650	3.012	4.221
14	0.692	0.868	1.076	1.345	1.761	2.145	2.624	2.977	4.140
15	0.691	0.866	1.074	1.341	1.753	2.131	2.602	2.947	4.073
16	0.690	0.865	1.071	1.337	1.746	2.120	2.583	2.921	4.015
17	0.689	0.863	1.069	1.333	1.740	2.110	2.567	2.898	3.965
18	0.688	0.862	1.067	1.330	1.734	2.101	2.552	2.878	3.922
19	0.688	0.861	1.066	1.328	1.729	2.093	2.539	2.861	3.883
20	0.687	0.860	1.064	1.325	1.725	2.086	2.528	2.845	3.850
21	0.686	0.859	1.063	1.323	1.721	2.080	2.518	2.831	3.819
22	0.686	0.858	1.061	1.321	1.717	2.074	2.508	2.819	3.792
23	0.685	0.858	1.060	1.319	1.714	2.069	2.500	2.807	3.768
24	0.685	0.857	1.059	1.318	1.711	2.064	2.492	2.797	3.745
25	0.684	0.856	1.058	1.316	1.708	2.060	2.485	2.787	3.725
26	0.684	0.856	1.058	1.315	1.706	2.056	2.479	2.779	3.707
27	0.684	0.855	1.057	1.314	1.703	2.052	2.473	2.771	3.689
28	0.683	0.855	1.056	1.313	1.701	2.048	2.467	2.763	3.674
29	0.683	0.854	1.055	1.311	1.699	2.045	2.462	2.756	3.660
30	0.683	0.854	1.055	1.310	1.697	2.042	2.457	2.750	3.646
40	0.681	0.851	1.050	1.303	1.684	2.021	2.423	2.704	3.551
60	0.679	0.848	1.045	1.296	1.671	2.000	2.390	2.660	3.460
120	0.677	0.845	1.041	1.289	1.658	1.980	2.358	2.617	3.373
∞	0.674	0.842	1.036	1.282	1.645	1.960	2.326	2.576	3.290

Tabla A.3: Cuantiles de la distribución chi-cuadrada.

v	α										
	0.995	0.990	0.975	0.950	0.900	0.500	0.100	0.050	0.025	0.010	0.005
1	0.0000	0.0002	0.0010	0.0039	0.0158	0.4549	2.7055	3.8415	5.0239	6.6349	7.8794
2	0.0100	0.0201	0.0506	0.1026	0.2107	1.3863	4.6052	5.9915	7.3778	9.2103	10.5966
3	0.0717	0.1148	0.2158	0.3518	0.5844	2.3660	6.2514	7.8147	9.3484	11.3449	12.8382
4	0.2070	0.2971	0.4844	0.7107	1.0636	3.3567	7.7794	9.4877	11.1433	13.2767	14.8603
5	0.4117	0.5543	0.8312	1.1455	1.6103	4.3515	9.2364	11.0705	12.8325	15.0863	16.7496
6	0.6757	0.8721	1.2373	1.6354	2.2041	5.3481	10.6446	12.5916	14.4494	16.8119	18.5476
7	0.9893	1.2390	1.6899	2.1673	2.8331	6.3458	12.0170	14.0671	16.0128	18.4753	20.2777
8	1.3444	1.6465	2.1797	2.7326	3.4895	7.3441	13.3616	15.5073	17.5345	20.0902	21.9550
9	1.7349	2.0879	2.7004	3.3251	4.1682	8.3428	14.6837	16.9190	19.0228	21.6660	23.5894
10	2.1559	2.5582	3.2470	3.9403	4.8652	9.3418	15.9872	18.3070	20.4832	23.2093	25.1882
11	2.6032	3.0535	3.8157	4.5748	5.5778	10.3410	17.2750	19.6751	21.9200	24.7250	26.7568
12	3.0738	3.5706	4.4038	5.2260	6.3038	11.3403	18.5493	21.0261	23.3367	26.2170	28.2995
13	3.5650	4.1069	5.0088	5.8919	7.0415	12.3398	19.8119	22.3620	24.7356	27.6882	29.8195
14	4.0747	4.6604	5.6287	6.5706	7.7895	13.3393	21.0641	23.6848	26.1189	29.1412	31.3193
15	4.6009	5.2293	6.2621	7.2609	8.5468	14.3389	22.3071	24.9958	27.4884	30.5779	32.8013
16	5.1422	5.8122	6.9077	7.9616	9.3122	15.3385	23.5418	26.2962	28.8454	31.9999	34.2672
17	5.6972	6.4078	7.5642	8.6718	10.0852	16.3382	24.7690	27.5871	30.1910	33.4087	35.7185
18	6.2648	7.0149	8.2307	9.3905	10.8649	17.3379	25.9894	28.8693	31.5264	34.8053	37.1565
19	6.8440	7.6327	8.9065	10.1170	11.6509	18.3377	27.2036	30.1435	32.8523	36.1909	38.5823
20	7.4338	8.2604	9.5908	10.8508	12.4426	19.3374	28.4120	31.4104	34.1696	37.5662	39.9968
21	8.0337	8.8972	10.2829	11.5913	13.2396	20.3372	29.6151	32.6706	35.4789	38.9322	41.4011
22	8.6427	9.5425	10.9823	12.3380	14.0415	21.3370	30.8133	33.9244	36.7807	40.2894	42.7957
23	9.2604	10.1957	11.6886	13.0905	14.8480	22.3369	32.0069	35.1725	38.0756	41.6384	44.1813
24	9.8862	10.8564	12.4012	13.8484	15.6587	23.3367	33.1962	36.4150	39.3641	42.9798	45.5585
25	10.5197	11.5240	13.1197	14.6114	16.4734	24.3366	34.3816	37.6525	40.6465	44.3141	46.9279
26	11.1602	12.1981	13.8439	15.3792	17.2919	25.3365	35.5632	38.8851	41.9232	45.6417	48.2899
27	11.8076	12.8785	14.5734	16.1514	18.1139	26.3363	36.7412	40.1133	43.1945	46.9629	49.6449
28	12.4613	13.5647	15.3079	16.9279	18.9392	27.3362	37.9159	41.3371	44.4608	48.2782	50.9934
29	13.1211	14.2565	16.0471	17.7084	19.7677	28.3361	39.0875	42.5570	45.7223	49.5879	52.3356
30	13.7867	14.9535	16.7908	18.4927	20.5992	29.3360	40.2560	43.7730	46.9792	50.8922	53.6720
40	20.7065	22.1643	24.4330	26.5093	29.0505	39.3353	51.8051	55.7585	59.3417	63.6907	66.7660
50	27.9907	29.7067	32.3574	34.7643	37.6886	49.3349	63.1671	67.5048	71.4202	76.1539	79.4900
60	35.5345	37.4849	40.4817	43.1880	46.4589	59.3347	74.3970	79.0819	83.2977	88.3794	91.9517
70	43.2752	45.4417	48.7576	51.7393	55.3289	69.3345	85.5270	90.5312	95.0232	100.4252	104.2149
80	51.1719	53.5401	57.1532	60.3915	64.2778	79.3343	96.5782	101.8795	106.6286	112.3288	116.3211
90	59.1963	61.7541	65.6466	69.1260	73.2911	89.3342	107.5650	113.1453	118.1359	124.1163	128.2989
100	67.3276	70.0649	74.2219	77.9295	82.3581	99.3341	118.4980	124.3421	129.5612	135.8067	140.1695
Z_α	-2.58	-2.33	-1.96	-1.64	-1.28	0.000	1.282	1.645	1.96	2.33	2.58

Para $v > 100$ tómese $X^2 = 1/2(Z_\alpha + \sqrt{2v - 1})^2$; con Z_α la desviación normal estandarizada correspondiente al nivel de significancia que se muestra en la parte inferior de la tabla.

Tabla A.4: Cuantiles de la distribución F : $P(F \geq F \text{ de tabla}) = \alpha$. gl: Grados de libertad

gl numerador		gl del denominador ν_2											
ν_1	α	1	2	3	4	5	6	7	8	9	10	11	12
1	0.100	39.86	8.526	5.5883	4.5448	4.0604	3.7759	3.5894	3.4579	3.3603	3.2850	3.2252	3.1765
	0.050	161.45	18.513	10.1280	7.7086	6.6079	5.9874	5.5914	5.3177	5.1174	4.9646	4.8443	4.7472
	0.025	647.79	38.506	17.4434	12.2179	10.0070	8.8131	8.0727	7.5709	7.2093	6.9367	6.7241	6.5538
	0.010	4052.18	98.503	34.1162	21.1977	16.2582	13.7450	12.2464	11.2586	10.5614	10.0443	9.6460	9.3302
	0.005	16210.72	198.501	55.5520	31.3328	22.7848	18.6350	16.2356	14.6882	13.6136	12.8265	12.2263	11.7542
2	0.100	49.50	9.000	5.4624	4.3246	3.7797	3.4633	3.2574	3.1131	3.0065	2.9245	2.8595	2.8068
	0.050	199.50	19.000	9.5521	6.9443	5.7861	5.1433	4.7374	4.4590	4.2565	4.1028	3.9823	3.8853
	0.025	799.50	39.000	16.0441	10.6491	8.4336	7.2599	6.5415	6.0595	5.7147	5.4564	5.2559	5.0959
	0.010	4999.50	99.000	30.8165	18.0000	13.2739	10.9248	9.5466	8.6491	8.0215	7.5594	7.2057	6.9266
	0.005	19999.50	199.000	49.7993	26.2843	18.3138	14.5441	12.4040	11.0424	10.1067	9.4270	8.9122	8.5096
3	0.100	53.59	9.162	5.3908	4.1909	3.6195	3.2888	3.0741	2.9238	2.8129	2.7277	2.6602	2.6055
	0.050	215.71	19.164	9.2766	6.5914	5.4095	4.7571	4.3468	4.0662	3.8625	3.7083	3.5874	3.4903
	0.025	864.16	39.165	15.4392	9.9792	7.7636	6.5988	5.8898	5.4160	5.0781	4.8256	4.6300	4.4742
	0.010	5403.35	99.166	29.4567	16.6944	12.0600	9.7795	8.4513	7.5910	6.9919	6.5523	6.2167	5.9525
	0.005	21614.74	199.166	47.4672	24.2591	16.5298	12.9166	10.8824	9.5965	8.7171	8.0807	7.6004	7.2258
4	0.100	55.83	9.243	5.3426	4.1072	3.5202	3.1808	2.9605	2.8064	2.6927	2.6053	2.5362	2.4801
	0.050	224.58	19.247	9.1172	6.3882	5.1922	4.5337	4.1203	3.8379	3.6331	3.4780	3.3567	3.2592
	0.025	899.58	39.248	15.1010	9.6045	7.3879	6.2272	5.5226	5.0526	4.7181	4.4683	4.2751	4.1212
	0.010	5624.58	99.249	28.7099	15.9770	11.3919	9.1483	7.8466	7.0061	6.4221	5.9943	5.6683	5.4120
	0.005	22499.58	199.250	46.1946	23.1545	15.5561	12.0275	10.0505	8.8051	7.9559	7.3428	6.8809	6.5211
5	0.100	57.24	9.293	5.3092	4.0506	3.4530	3.1075	2.8833	2.7264	2.6106	2.5216	2.4512	2.3940
	0.050	230.16	19.296	9.0135	6.2561	5.0503	4.3874	3.9715	3.6875	3.4817	3.3258	3.2039	3.1059
	0.025	921.85	39.298	14.8848	9.3645	7.1464	5.9876	5.2852	4.8173	4.4844	4.2361	4.0440	3.8911
	0.010	5763.65	99.299	28.2371	15.5219	10.9670	8.7459	7.4604	6.6318	6.0569	5.6363	5.3160	5.0643
	0.005	23055.80	199.300	45.3916	22.4564	14.9396	11.4637	9.5221	8.3018	7.4712	6.8724	6.4217	6.0711
6	0.100	58.20	9.326	5.2847	4.0097	3.4045	3.0546	2.8274	2.6683	2.5509	2.4606	2.3891	2.3310
	0.050	233.99	19.330	8.9406	6.1631	4.9503	4.2839	3.8660	3.5806	3.3738	3.2172	3.0946	2.9961
	0.025	937.11	39.331	14.7847	9.1973	6.9777	5.8198	5.1186	4.6517	4.3197	4.0721	3.8807	3.7283
	0.010	5858.99	99.333	27.9107	15.2069	10.6723	8.4661	7.1914	6.3707	5.8018	5.3858	5.0692	4.8206
	0.005	23437.11	199.333	44.8385	21.9746	14.5133	11.0730	9.1553	7.9520	7.1339	6.5446	6.1016	5.7570
7	0.100	58.91	9.349	5.2662	3.9790	3.3679	3.0145	2.7849	2.6241	2.5053	2.4140	2.3416	2.2828
	0.050	236.77	19.353	8.8867	6.0942	4.8759	4.2067	3.7870	3.5005	3.2927	3.1355	3.0123	2.9134
	0.025	948.22	39.355	14.6244	9.0741	6.8531	5.6955	4.9949	4.5286	4.1970	3.9498	3.7586	3.6065
	0.010	5928.36	99.356	27.6717	14.9758	10.4555	8.2600	6.9928	6.1776	5.6129	5.2001	4.8861	4.6395
	0.005	23714.57	199.357	44.4341	21.6217	14.2004	10.7859	8.8854	7.6941	6.8849	6.3025	5.8648	5.5245
8	0.100	59.44	9.367	5.2517	3.9549	3.3393	2.9830	2.7516	2.5893	2.4694	2.3772	2.3040	2.2446
	0.050	238.88	19.371	8.8452	6.0410	4.8183	4.1468	3.7257	3.4381	3.2296	3.0717	2.9480	2.8486
	0.025	956.66	39.373	14.5399	8.9796	6.7572	5.5996	4.8993	4.4333	4.1020	3.8549	3.6638	3.5118
	0.010	5981.07	99.374	27.4892	14.7989	10.2893	8.1017	6.8400	6.0289	5.4671	5.0567	4.7445	4.4994
	0.005	23925.41	199.375	44.1256	21.3520	13.9610	10.5658	8.6781	7.4959	6.6933	6.1159	5.6821	5.3451
9	0.100	59.86	9.381	5.2400	3.9357	3.3163	2.9577	2.7247	2.5612	2.4403	2.3473	2.2735	2.2135
	0.050	240.54	19.385	8.8123	5.9988	4.7725	4.0990	3.6767	3.3881	3.1789	3.0204	2.8962	2.7964
	0.025	963.28	39.387	14.4731	8.9047	6.6811	5.5234	4.8232	4.3572	4.0260	3.7790	3.5879	3.4358
	0.010	6022.47	99.388	27.3452	14.6591	10.1578	7.9761	6.7188	5.9106	5.3511	4.9424	4.6315	4.3875
	0.005	24491.00	199.388	43.8824	21.1391	13.7716	10.3915	8.5138	7.3386	6.5411	5.9676	5.5368	5.2021
10	0.100	60.19	9.392	5.2304	3.9199	3.2974	2.9369	2.7025	2.5380	2.4163	2.3226	2.2482	2.1878
	0.050	241.88	19.396	8.7855	5.9644	4.7351	4.0600	3.6365	3.3472	3.1373	2.9782	2.8536	2.7534
	0.025	968.63	39.398	14.4189	8.8439	6.6192	5.4613	4.7611	4.2951	3.9639	3.7168	3.5257	3.3736
	0.010	6055.85	99.399	27.2287	14.5459	10.0510	7.8741	6.6201	5.8143	5.2565	4.8491	4.5393	4.2961
	0.005	24224.49	199.400	43.6858	20.9667	13.6182	10.2500	8.3803	7.2106	6.4172	5.8467	5.4183	5.0855
11	0.100	60.47	9.401	5.2224	3.9067	3.2816	2.9195	2.6839	2.5186	2.3961	2.3018	2.2269	2.1660
	0.050	242.98	19.405	8.7633	5.9358	4.7040	4.0274	3.6030	3.3130	3.1025	2.9430	2.8179	2.7173
	0.025	973.03	39.407	14.3742	8.7935	6.5678	5.4098	4.7095	4.2434	3.9121	3.6649	3.4737	3.3215
	0.010	6083.32	99.408	27.1326	14.4523	9.9626	7.7896	6.5382	5.7343	5.1779	4.7715	4.4624	4.2198
	0.005	24334.36	199.409	43.5236	20.8243	13.4912	10.1329	8.2697	7.1045	6.3142	5.7462	5.3197	4.9884
12	0.100	60.71	9.408	5.2156	3.8955	3.2682	2.9047	2.6681	2.5020	2.3789	2.2841	2.2087	2.1474
	0.050	243.91	19.413	8.7446	5.9117	4.6777	3.9999	3.57468	3.28394	3.07295	2.91298	2.78757	2.68664
	0.025	976.71	39.415	14.3366	8.7512	6.5245	5.3662	4.66583	4.19967	3.86822	3.62095	3.42961	3.27728
	0.010	6106.32	99.416	27.0518	14.3736	9.8883	7.7183	6.46909	5.66672	5.11143	4.70587	4.39740	4.15526
	0.005	24426.37	199.416	43.3874	20.7047	13.3845	10.0343	8.17641	7.01492	6.22737	5.66133	5.23633	4.90625

(Continuación Tabla A.4.)

gl numerador		gl del denominador											
ν_1	α	ν_2											
		1	2	3	4	5	6	7	8	9	10	11	12
13	0.100	60.90	9.415	5.2098	3.8859	3.2567	2.8920	2.65449	2.48765	2.36401	2.26871	2.19298	2.13134
	0.050	244.69	19.419	8.7287	5.8911	4.6552	3.9764	3.55034	3.25902	3.04755	2.88717	2.76142	2.66018
	0.025	979.84	39.421	14.3045	8.7150	6.4876	5.3290	4.62846	4.16217	3.83060	3.58319	3.39173	3.23926
	0.010	6125.86	99.422	26.9831	14.3065	9.8248	7.6575	6.41003	5.60891	5.05451	4.64961	4.34162	4.09985
	0.005	24504.54	199.423	43.2715	20.6027	13.2934	9.9501	8.09675	6.93886	6.15304	5.58866	5.16493	4.83584
14	0.100	61.07	9.420	5.2047	3.8776	3.2468	2.8809	2.64264	2.47518	2.35104	2.25531	2.17922	2.11727
	0.050	245.36	19.424	8.7149	5.8733	4.6358	3.9559	3.52923	3.23738	3.02547	2.86473	2.73865	2.63712
	0.025	982.53	39.427	14.2768	8.6838	6.4556	5.2968	4.59609	4.12967	3.79795	3.55041	3.35881	3.20621
	0.010	6142.67	99.428	26.9238	14.2486	9.7700	7.6049	6.35895	5.55887	5.00521	4.60083	4.29324	4.05176
	0.005	24571.77	199.428	43.1716	20.5148	13.2148	9.8774	8.02789	6.87213	6.08870	5.52572	5.10805	4.77480
15	0.100	61.22	9.425	5.2003	3.8704	3.2380	2.8712	2.63223	2.46422	2.33962	2.24351	2.16709	2.10485
	0.050	245.95	19.429	8.7029	5.8578	4.6188	3.9381	3.51074	3.21841	3.00610	2.84502	2.71864	2.61685
	0.025	984.87	39.431	14.2527	8.6565	6.4277	5.2687	4.56779	4.10121	3.76936	3.52167	3.32993	3.17720
	0.010	6157.28	99.433	26.8722	14.1982	9.7222	7.5590	6.31433	5.51512	4.96208	4.55814	4.25087	4.00962
	0.005	24630.21	199.433	43.0847	20.4383	13.1463	9.8140	7.96777	6.81428	6.03246	5.47066	5.04890	4.72134
16	0.100	61.35	9.429	5.1964	3.8639	3.2303	2.8626	2.62301	2.45450	2.32950	2.23304	2.15632	2.09381
	0.050	246.46	19.433	8.6923	5.8441	4.6038	3.9223	3.49441	3.20163	2.98897	2.82757	2.70091	2.59888
	0.025	986.92	39.435	14.2315	8.6326	6.4032	5.2439	4.54282	4.07610	3.74410	3.49627	3.30439	3.15153
	0.010	6170.10	99.437	26.8269	14.1539	9.6802	7.5186	6.27501	5.47655	4.92402	4.52045	4.21344	3.97237
	0.005	24681.47	199.437	43.0083	20.3710	13.0861	9.7582	7.91482	6.76329	5.98286	5.42209	5.00110	4.67413
20	0.100	61.74	9.441	5.1845	3.8443	3.2067	2.8363	2.59473	2.42464	2.29832	2.20074	2.12305	2.05968
	0.050	248.01	19.446	8.6602	5.8025	4.5581	3.8742	3.44452	3.15032	2.93646	2.77402	2.64645	2.54359
	0.025	993.10	39.448	14.1674	8.5599	6.3286	5.1684	4.46674	3.99945	3.66691	3.41854	3.22614	3.07277
	0.010	6208.73	99.449	26.6898	14.0196	9.5526	7.3958	6.15544	5.35909	4.80800	4.40539	4.09905	3.85843
	0.005	24835.97	199.450	42.7775	20.1673	12.9035	9.5888	7.75396	6.60820	5.83184	5.27402	4.85522	4.52992
25	0.100	62.05	9.451	5.1747	3.8283	3.1873	2.8147	2.57139	2.39992	2.27246	2.17388	2.09531	2.03116
	0.050	249.26	19.456	8.6341	5.7687	4.5209	3.8348	3.40361	3.10813	2.89318	2.72978	2.60136	2.49773
	0.025	998.08	39.458	14.1155	8.5010	6.2679	5.1069	4.40455	3.93666	3.60353	3.35460	3.16164	3.00774
	0.010	6239.83	99.459	26.5790	13.9109	9.4491	7.2960	6.05795	5.26314	4.71303	4.31106	4.00509	3.76469
	0.005	24960.34	199.460	42.5910	20.0024	12.7554	9.4511	7.62299	6.48171	5.70844	5.15282	4.73563	4.41151
30	0.100	62.26	9.458	5.1681	3.8174	3.1741	2.8000	2.55546	2.38302	2.25472	2.15543	2.07621	2.01149
	0.050	250.10	19.462	8.6166	5.7459	4.4957	3.8082	3.37581	3.07941	2.86365	2.69955	2.57049	2.46628
	0.025	1001.41	39.465	14.0805	8.4613	6.2269	5.0652	4.36239	3.89402	3.56041	3.31102	3.11762	2.96328
	0.010	6260.65	99.466	26.5045	13.8377	9.3793	7.2285	5.99201	5.19813	4.64858	4.24693	3.94113	3.70079
	0.005	25043.63	199.466	42.4658	19.8915	12.6556	9.3582	7.53449	6.39609	5.62479	5.07055	4.65434	4.33092
40	0.100	62.53	9.466	5.1597	3.8036	3.1573	2.7812	2.53510	2.36136	2.23196	2.13169	2.05161	1.98610
	0.050	251.14	19.471	8.5944	5.7170	4.4638	3.7743	3.34043	3.04278	2.82593	2.66086	2.53091	2.42588
	0.025	1005.60	39.473	14.0365	8.4111	6.1750	5.0125	4.30888	3.83978	3.50547	3.25540	3.06133	2.90635
	0.010	6286.78	99.474	26.4108	13.7454	9.2912	7.1432	5.90845	5.11561	4.56665	4.16529	3.85937	3.61918
	0.005	25148.15	199.475	42.3082	19.7518	12.5297	9.2408	7.42245	6.28754	5.51858	4.96594	4.55082	4.22815
60	0.100	62.79	9.475	5.1512	3.7896	3.1402	2.7620	2.51422	2.33910	2.20849	2.10716	2.02612	1.95973
	0.050	252.20	19.479	8.5720	5.6877	4.4314	3.7398	3.30432	3.00530	2.78725	2.62108	2.49012	2.38417
	0.025	1009.80	39.481	13.9921	8.3604	6.1225	4.9589	4.25440	3.78445	3.44930	3.19840	3.00353	2.84777
	0.010	6313.03	99.482	26.3164	13.6522	9.2020	7.0567	5.82357	5.03162	4.48309	4.08186	3.77607	3.53547
	0.005	25253.14	199.483	42.1494	19.6107	12.4024	9.1219	7.30875	6.17718	5.41041	4.85919	4.44500	4.12292
80	0.100	62.93	9.479	5.1469	3.7825	3.1316	2.7522	2.50358	2.32772	2.19648	2.09458	2.01301	1.94615
	0.050	252.72	19.483	8.5607	5.6730	4.4150	3.7223	3.28598	2.98623	2.76752	2.60075	2.46925	2.36277
	0.025	1011.91	39.485	13.9697	8.3349	6.0960	4.9318	4.22678	3.75634	3.42072	3.16935	2.97402	2.81781
	0.010	6326.20	99.487	26.2688	13.6053	9.1570	7.0130	5.78061	4.98904	4.44066	4.03942	3.73353	3.49276
	0.005	25305.80	199.487	42.0696	19.5397	12.3383	9.0619	7.25126	6.12129	5.35553	4.80496	4.39116	4.06929
120	0.100	63.06	9.483	5.1425	3.7753	3.1228	2.7423	2.49279	2.31618	2.18427	2.08176	1.99965	1.93228
	0.050	253.25	19.487	8.5494	5.6581	4.3985	3.7047	3.26745	2.96692	2.74752	2.58012	2.44802	2.34099
	0.025	1014.02	39.490	13.9473	8.3092	6.0693	4.90445	4.19890	3.72794	3.39180	3.13991	2.94408	2.78737
	0.010	6339.39	99.491	26.2211	13.5581	9.1118	6.96902	5.73729	4.94605	4.39777	3.99648	3.69044	3.44944
	0.005	25358.57	199.491	41.9895	19.4684	12.2737	9.00146	7.19332	6.06490	5.30011	4.75013	4.33666	4.01495
∞	0.100	63.33	9.491	5.1337	3.7607	3.1050	2.72219	2.47081	2.29260	2.15926	2.05545	1.97214	1.90865
	0.050	254.31	19.496	8.5265	5.6281	4.3650	3.66891	3.22980	2.92762	2.70672	2.53793	2.40452	2.29625
	0.025	1018.25	39.498	13.9021	8.2574	6.0154	4.84916	4.14240	3.67025	3.33292	3.07986	2.88286	2.72500
	0.010	6365.83	99.499	26.1253	13.4632	9.0205	6.88013	5.64963	4.85890	4.31066	3.90909	3.60253	3.36092
	0.005	25464.33	199.500	41.8285	19.3249	12.1437	8.87948	7.07617	5.95069	5.18766	4.63866	4.22567	3.90407

(Continuación Tabla A.4.)

gl numerador		gl del denominador												
v_1	α	13	14	15	16	20	25	30	40	60	80	120	∞	
1	0.100	3.1362	3.1022	3.0732	3.0481	2.97465	2.91774	2.88069	2.83535	2.79107	2.76931	2.74781	2.70559	
	0.050	4.6672	4.6001	4.5431	4.4940	4.35124	4.24170	4.17088	4.08475	4.00119	3.96035	3.92012	3.84155	
	0.025	6.4143	6.2979	6.1995	6.1151	5.87149	5.68637	5.56753	5.42394	5.28561	5.21835	5.15233	5.02404	
	0.010	9.0738	8.8616	8.6831	8.5310	8.09596	7.76980	7.56248	7.31410	7.07711	6.96269	6.85089	6.63515	
	0.005	11.3735	11.0603	10.7980	10.5755	9.94393	9.47531	9.17968	8.82786	8.49462	8.33461	8.17883	7.87979	
2	0.100	2.7632	2.7265	2.6952	2.6682	2.58925	2.52831	2.48872	2.44037	2.39325	2.37015	2.34734	2.30264	
	0.050	3.8056	3.7389	3.6823	3.6337	3.49283	3.38519	3.31583	3.23173	3.15041	3.11077	3.07178	2.99582	
	0.025	4.9653	4.8567	4.7650	4.6867	4.46126	4.29093	4.18206	4.05099	3.92527	3.86433	3.80464	3.68902	
	0.010	6.7010	6.5149	6.3589	6.2262	5.84893	5.56800	5.39035	5.17851	4.97743	4.88074	4.78651	4.60538	
	0.005	8.1865	7.9216	7.7008	7.5138	6.98646	6.59820	6.35469	6.06643	5.79499	5.66524	5.53929	5.29860	
3	0.100	2.5603	2.5222	2.4898	2.4618	2.38009	2.31702	2.27607	2.22609	2.17741	2.15355	2.12999	2.08385	
	0.050	3.4105	3.3439	3.2874	3.2389	3.09839	2.99124	2.92228	2.83875	2.75808	2.71878	2.68017	2.60500	
	0.025	4.3472	4.2417	4.1528	4.0768	3.85870	3.69427	3.58936	3.46326	3.34252	3.28408	3.22689	3.11626	
	0.010	5.7394	5.5639	5.4170	5.2922	4.93819	4.67546	4.50974	4.31257	4.12589	4.03630	3.94910	3.78182	
	0.005	6.9258	6.6804	6.4760	6.3034	5.81770	5.46152	5.23879	4.97584	4.72899	4.61127	4.49717	4.27964	
4	0.100	2.4337	2.3947	2.3614	2.3327	2.24893	2.18424	2.14223	2.09095	2.04099	2.01649	1.99230	1.94492	
	0.050	3.1791	3.1122	3.0556	3.0069	2.86608	2.75871	2.68963	2.60597	2.52522	2.48588	2.44724	2.37202	
	0.025	3.9959	3.8919	3.8043	3.7294	3.51470	3.35301	3.24993	3.12611	3.00766	2.95036	2.89431	2.78595	
	0.010	5.2053	5.0354	4.8932	4.7726	4.43069	4.17742	4.01788	3.82829	3.64905	3.56311	3.47953	3.31936	
	0.005	6.2335	5.9984	5.8029	5.6378	5.17428	4.83509	4.62336	4.37378	4.13989	4.02851	3.92065	3.71530	
5	0.100	2.3467	2.3069	2.2730	2.2438	2.15823	2.09216	2.04925	1.99682	1.94571	1.92064	1.89587	1.84733	
	0.050	3.0254	2.9582	2.9013	2.8524	2.71089	2.60299	2.53355	2.44947	2.36827	2.32872	2.28985	2.21419	
	0.025	3.7667	3.6634	3.5764	3.5021	3.28906	3.12868	3.02647	2.90372	2.78631	2.72953	2.67399	2.56663	
	0.010	4.8616	4.6950	4.5556	4.4374	4.10268	3.85496	3.69902	3.51384	3.33888	3.25505	3.17355	3.01744	
	0.005	5.7910	5.5623	5.3721	5.2117	4.76157	4.43267	4.22758	3.98605	3.75995	3.65236	3.54823	3.35015	
6	0.100	2.2830	2.2426	2.2081	2.1783	2.09132	2.02406	1.98033	1.92688	1.87472	1.84911	1.82381	1.77417	
	0.050	2.9153	2.8477	2.7905	2.7413	2.59898	2.49041	2.42052	2.33585	2.25405	2.21419	2.17501	2.09869	
	0.025	3.6043	3.5014	3.4147	3.3406	3.12834	2.96855	2.86670	2.74438	2.62737	2.57077	2.51540	2.40836	
	0.010	4.6204	4.4558	4.3183	4.2016	3.87143	3.62717	3.47348	3.29101	3.11867	3.03611	2.95585	2.80216	
	0.005	5.4819	5.2574	5.0708	4.9134	4.47215	4.14999	3.94921	3.71291	3.49183	3.38668	3.28494	3.09149	
7	0.100	2.2341	2.1931	2.1582	2.1280	2.03970	1.97138	1.92692	1.87252	1.81939	1.79329	1.76748	1.71678	
	0.050	2.8321	2.7642	2.7066	2.6572	2.51401	2.40473	2.33434	2.24902	2.16654	2.12632	2.08677	2.00968	
	0.025	3.4827	3.3799	3.2934	3.2194	3.00742	2.84780	2.74603	2.62378	2.50679	2.45018	2.39479	2.28766	
	0.010	4.4410	4.2779	4.1415	4.0259	3.69874	3.45675	3.30450	3.12376	2.95305	2.87127	2.79176	2.63951	
	0.005	5.2529	5.0313	4.8473	4.6920	4.25689	3.93937	3.74156	3.50881	3.29111	3.18759	3.08744	2.89704	
8	0.100	2.1953	2.1539	2.1185	2.0880	1.99853	1.92925	1.88412	1.82886	1.77483	1.74825	1.72196	1.67026	
	0.050	2.7669	2.6987	2.6408	2.5911	2.44706	2.33706	2.26616	2.18017	2.09697	2.05637	2.01643	1.93851	
	0.025	3.3880	3.2853	3.1987	3.1248	2.91280	2.75311	2.65126	2.52886	2.41167	2.35494	2.29941	2.19194	
	0.010	4.3021	4.1399	4.0045	3.8896	3.56441	3.32394	3.17262	2.99298	2.82328	2.74196	2.66291	2.51146	
	0.005	5.0761	4.8566	4.6744	4.5207	4.08997	3.77577	3.58006	3.34979	3.13444	3.03203	2.93296	2.74459	
9	0.100	2.1638	2.1220	2.0862	2.0553	1.96485	1.89469	1.84896	1.79290	1.73802	1.71100	1.68425	1.63158	
	0.050	2.7144	2.6458	2.5876	2.5377	2.39281	2.28210	2.21070	2.12403	2.04010	1.99911	1.95876	1.87998	
	0.025	3.3120	3.2093	3.1227	3.0488	2.83655	2.67664	2.57461	2.45194	2.33441	2.27748	2.22173	2.11377	
	0.010	4.1911	4.0297	3.8948	3.7804	3.45668	3.21722	3.06652	2.88756	2.71845	2.63740	2.55857	2.40751	
	0.005	4.9351	4.7173	4.5364	4.3838	3.95644	3.64468	3.45048	3.22198	3.00827	2.90662	2.80828	2.62126	
10	0.100	2.1376	2.0954	2.0593	2.0281	1.93674	1.86578	1.81949	1.76269	1.70701	1.67957	1.65238	1.59878	
	0.050	2.6710	2.6022	2.5437	2.4935	2.34788	2.23647	2.16458	2.07725	1.99259	1.95122	1.91046	1.83080	
	0.025	3.2497	3.1469	3.0602	2.9862	2.77367	2.61347	2.51119	2.38816	2.27020	2.21303	2.15701	2.04845	
	0.010	4.1003	3.9394	3.8049	3.6909	3.36819	3.12941	2.97909	2.80055	2.63175	2.55081	2.47208	2.32110	
	0.005	4.8199	4.6034	4.4235	4.2719	3.84700	3.53705	3.34396	3.11675	2.90418	2.80305	2.70520	2.51903	
11	0.100	2.1155	2.0729	2.0366	2.0051	1.91288	1.84120	1.79438	1.73689	1.68046	1.65262	1.62501	1.57052	
	0.050	2.6347	2.5655	2.5068	2.4564	2.30999	2.19793	2.12556	2.03758	1.95221	1.91046	1.86929	1.78874	
	0.025	3.1975	3.0946	3.0078	2.9337	2.72086	2.56030	2.45775	2.33431	2.21586	2.15842	2.10210	1.99286	
	0.010	4.0245	3.8640	3.7299	3.6162	3.29411	3.05577	2.90569	2.72735	2.55867	2.47775	2.39900	2.24790	
	0.005	4.7240	4.5085	4.3295	4.1785	3.75555	3.44697	3.25471	3.02842	2.81664	2.71586	2.61832	2.43266	
12	0.100	2.0966	2.0537	2.0171	1.9854	1.89236	1.82000	1.77270	1.71456	1.65743	1.62921	1.60120	1.54585	
	0.050	2.6036	2.5342	2.4753	2.4246	2.27758	2.16489	2.09206	2.00346	1.91740	1.87526	1.83370	1.75227	
	0.025	3.1531	3.0501	2.9632	2.8890	2.67583	2.51489	2.41203	2.28816	2.16919	2.11145	2.05482	1.94485	
	0.010	3.9603	3.8001	3.6662	3.5527	3.23112	2.99306	2.84310	2.66483	2.49612	2.41514	2.33630	2.18492	
	0.005	4.6429	4.4281	4.2497	4.0994	3.67791	3.37038	3.17873	2.95310	2.74186	2.64130	2.54393	2.35851	

(Continuación Tabla A.4.)

v_1	gl numerador		gl del denominador											
	α	v_2												
			13	14	15	16	20	25	30	40	60	80	120	∞
13	0.100	2.08019	2.03704	2.00015	1.96824	1.87451	1.80153	1.75378	1.69503	1.63723	1.60865	1.58026	1.52406	
	0.050	2.57693	2.50726	2.44811	2.39725	2.24951	2.13623	2.06296	1.97376	1.88702	1.84451	1.80255	1.72025	
	0.025	3.11504	3.01189	2.92490	2.85056	2.63694	2.47561	2.37244	2.24811	2.12861	2.07056	2.01360	1.90287	
	0.010	3.90520	3.74524	3.61151	3.49810	3.17686	2.93895	2.78902	2.61073	2.44188	2.36079	2.28181	2.13004	
	0.005	4.57328	4.35915	4.18131	4.03136	3.61111	3.30439	3.11320	2.88804	2.67714	2.57669	2.47941	2.29402	
14	0.100	2.06583	2.02243	1.98532	1.95321	1.85883	1.78527	1.73710	1.67778	1.61934	1.59041	1.56166	1.50465	
	0.050	2.55362	2.48373	2.42436	2.37332	2.22496	2.11111	2.03742	1.94764	1.86024	1.81738	1.77503	1.69187	
	0.025	3.08185	2.97859	2.89148	2.81702	2.60300	2.44126	2.33777	2.21298	2.09294	2.03458	1.97728	1.86577	
	0.010	3.85734	3.69754	3.56394	3.45063	3.12960	2.89175	2.74181	2.56340	2.39435	2.31311	2.23395	2.08170	
	0.005	4.51289	4.29929	4.12189	3.97229	3.55300	3.24690	3.05605	2.83120	2.62050	2.52010	2.42282	2.23731	
15	0.100	2.05316	2.00953	1.97222	1.93992	1.84494	1.77083	1.72227	1.66241	1.60337	1.57411	1.54500	1.48721	
	0.050	2.53311	2.46300	2.40345	2.35222	2.20327	2.08889	2.01480	1.92446	1.83644	1.79322	1.75050	1.66649	
	0.025	3.05271	2.94932	2.86209	2.78752	2.57310	2.41095	2.30715	2.18190	2.06131	2.00264	1.94499	1.83269	
	0.010	3.81537	3.65570	3.52219	3.40895	3.08804	2.85019	2.70018	2.52162	2.35230	2.27088	2.19150	2.03871	
	0.005	4.45998	4.24682	4.06978	3.92048	3.50196	3.19634	3.00573	2.78108	2.57046	2.47005	2.37271	2.18697	
16	0.100	2.04189	1.99805	1.96055	1.92808	1.83253	1.75793	1.70900	1.64863	1.58901	1.55944	1.52999	1.47143	
	0.050	2.51492	2.44461	2.38488	2.33348	2.18398	2.06909	1.99462	1.90375	1.81511	1.77156	1.72846	1.64362	
	0.025	3.02691	2.92339	2.83605	2.76136	2.54654	2.38400	2.27989	2.15418	2.03304	1.97406	1.91607	1.80297	
	0.010	3.77825	3.61868	3.48525	3.37205	3.05120	2.81329	2.66819	2.48442	2.31480	2.23318	2.15357	2.00018	
	0.005	4.41324	4.20045	4.02371	3.87465	3.45676	3.15150	2.96105	2.73653	2.52590	2.42543	2.32799	2.14192	
20	0.100	2.00698	1.96245	1.92431	1.89127	1.79384	1.71752	1.66731	1.60515	1.54349	1.51276	1.48207	1.42067	
	0.050	2.45888	2.38790	2.32754	2.27557	2.12416	2.00747	1.93165	1.83886	1.74798	1.70316	1.65868	1.57063	
	0.025	2.94767	2.84369	2.75590	2.68079	2.46448	2.30045	2.19516	2.06771	1.94447	1.88427	1.82492	1.70862	
	0.010	3.66461	3.50522	3.37189	3.25874	2.93774	2.69932	2.54866	2.36888	2.19781	2.11527	2.03459	1.87850	
	0.005	4.27032	4.05853	3.88259	3.73417	3.31779	3.01327	2.82304	2.59842	2.38720	2.28622	2.18811	2.00006	
25	0.100	1.97776	1.93260	1.89387	1.86030	1.76108	1.68310	1.63163	1.56767	1.50389	1.47196	1.43992	1.37534	
	0.050	2.41232	2.34069	2.27973	2.22721	2.07392	1.95545	1.87825	1.78346	1.69019	1.64398	1.59796	1.50621	
	0.025	2.88212	2.77765	2.68940	2.61384	2.39594	2.23030	2.12372	1.99434	1.86872	1.80711	1.74617	1.62600	
	0.010	3.57096	3.41159	3.27822	3.16497	2.84340	2.60411	2.45260	2.27140	2.09837	2.01461	1.93249	1.77275	
	0.005	4.15279	3.94168	3.76623	3.61818	3.20254	2.89812	2.70764	2.48229	2.26975	2.16783	2.06856	1.87734	
30	0.100	1.95757	1.91193	1.87277	1.83879	1.73822	1.65895	1.60648	1.54108	1.47554	1.44258	1.40938	1.34195	
	0.050	2.38033	2.30821	2.24679	2.19384	2.03909	1.91919	1.84087	1.74443	1.64914	1.60173	1.55434	1.45921	
	0.025	2.83725	2.73238	2.64374	2.56781	2.34860	2.18162	2.07394	1.94292	1.81520	1.75233	1.68994	1.56612	
	0.010	3.50704	3.34760	3.21411	3.10073	2.77848	2.53831	2.38597	2.20338	2.02848	1.94353	1.86001	1.69660	
	0.005	4.07270	3.86194	3.68675	3.53887	3.12341	2.81871	2.62778	2.40148	2.18743	2.08449	1.98395	1.78930	
40	0.100	1.93147	1.88516	1.84539	1.81084	1.70833	1.62718	1.57323	1.50562	1.43734	1.40272	1.36760	1.29522	
	0.050	2.33918	2.26635	2.20428	2.15071	1.99382	1.87180	1.79179	1.69280	1.59427	1.54489	1.49520	1.39409	
	0.025	2.77969	2.67422	2.58501	2.50853	2.28732	2.11826	2.00887	1.87520	1.74405	1.67904	1.61415	1.48370	
	0.010	3.42529	3.26564	3.13191	3.01825	2.69475	2.45299	2.29921	2.11423	1.93602	1.84893	1.76285	1.59247	
	0.005	3.97044	3.76000	3.58499	3.43721	3.02153	2.71598	2.52406	2.29584	2.07887	1.97393	1.87095	1.66939	
60	0.100	1.90429	1.85723	1.81676	1.78156	1.67678	1.59335	1.53757	1.46716	1.39520	1.35825	1.32034	1.24005	
	0.050	2.29660	2.22295	2.16011	2.10581	1.94636	1.82173	1.73957	1.63725	1.53431	1.48211	1.42901	1.31817	
	0.025	2.72036	2.61415	2.52423	2.44707	2.22336	2.05164	1.94001	1.80277	1.66679	1.59866	1.52994	1.38847	
	0.010	3.34129	3.18127	3.04713	2.93305	2.60771	2.36369	2.20785	2.01941	1.83626	1.74588	1.65569	1.47321	
	0.005	3.86553	3.65525	3.48027	3.33241	2.91588	2.60875	2.41515	2.18384	1.96217	1.85398	1.74685	1.53279	
80	0.100	1.89026	1.84279	1.80193	1.76636	1.66028	1.57554	1.51866	1.44652	1.37221	1.33370	1.29382	1.20734	
	0.050	2.27472	2.20061	2.13733	2.08262	1.92169	1.79551	1.71206	1.60767	1.50185	1.44773	1.39220	1.27365	
	0.025	2.68996	2.58333	2.49298	2.41542	2.19023	2.01690	1.90388	1.76437	1.62519	1.55488	1.48340	1.33305	
	0.010	3.29836	3.13809	3.00368	2.88931	2.56277	2.31730	2.16011	1.96937	1.78282	1.69007	1.59683	1.40435	
	0.005	3.81200	3.60172	3.42667	3.27870	2.86145	2.55316	2.35837	2.12490	1.89984	1.78924	1.67894	1.45429	
120	0.100	1.87591	1.82800	1.78672	1.75075	1.64326	1.55703	1.49891	1.42476	1.34757	1.30707	1.26457	1.16873	
	0.050	2.25241	2.17781	2.11406	2.05890	1.89632	1.76840	1.68345	1.57661	1.46727	1.41068	1.35189	1.22157	
	0.025	2.65903	2.55192	2.46112	2.38311	2.15624	1.98106	1.86642	1.72420	1.58103	1.50791	1.43268	1.26865	
	0.010	3.25476	3.09419	2.95945	2.84474	2.51678	2.26956	2.11076	1.91719	1.72632	1.63045	1.53299	1.32486	
	0.005	3.75769	3.54735	3.37218	3.22403	2.80580	2.49605	2.29977	2.06356	1.83411	1.72025	1.60551	1.36405	
∞	0.100	1.84623	1.79732	1.75509	1.71821	1.60742	1.51765	1.45642	1.37697	1.29154	1.24468	1.19267	1.00814	
	0.050	2.20649	2.13075	2.06591	2.00970	1.84325	1.71106	1.62234	1.50899	1.38938	1.32481	1.25400	1.01046	
	0.025	2.59534	2.48732	2.39543	2.31635	2.08542	1.90562	1.78680	1.63724	1.48228	1.39989	1.31061	1.01247	
	0.010	3.16550	3.00413	2.86854	2.75294	2.42131	2.16951	2.00636	1.80485	1.60081	1.49439	1.38074	1.01482	
	0.005	3.64666	3.43599	3.26036	3.11164	2.69054	2.37665	2.17616	1.93192	1.68869	1.56357	1.43134	1.01642	

Tabla A.5: Valores de la función de distribución de U $P(U \leq U_0)$; U_0 es el argumento; $n_1 \leq n_2$; $3 \leq n_2 \leq 10$

$n_2 = 3$					
U_0	n_1				
	1	2	3		
0	0.25	0.10	0.05		
1	0.50	0.20	0.10		
2		0.40	0.20		
3		0.60	0.35		
4			0.50		

$n_2 = 4$					
U_0	n_1				
	1	2	3	4	
0	0.2000	0.0667	0.0286	0.0143	
1	0.4000	0.1333	0.0571	0.0286	
2	0.6000	0.2667	0.1143	0.0571	
3		0.4000	0.2000	0.1000	
4		0.6000	0.3143	0.1714	
5			0.4286	0.2429	
6			0.5714	0.3429	
7				0.4429	
8				0.5571	

$n_2 = 5$					
U_0	n_1				
	1	2	3	4	5
0	0.1667	0.0476	0.0179	0.0079	0.0040
1	0.3333	0.0952	0.0357	0.0159	0.0079
2	0.5000	0.1905	0.0714	0.0317	0.0159
3		0.2857	0.1250	0.0556	0.0278
4		0.4286	0.1964	0.0952	0.0476
5		0.5714	0.2857	0.1429	0.0754
6			0.3929	0.2063	0.1111
7			0.5000	0.2778	0.1548
8				0.3651	0.2103
9				0.4524	0.2738
10				0.5476	0.3452
11					0.4206
12					0.5000

(Continuación Tabla A.5)

$n_2 = 6$						
U_0	n_1					
	1	2	3	4	5	6
0	0.1429	0.0357	0.0119	0.0048	0.0022	0.0011
1	0.2857	0.0714	0.0238	0.0095	0.0043	0.0022
2	0.4286	0.1429	0.0476	0.0190	0.0087	0.0043
3	0.5714	0.2143	0.0833	0.0333	0.0152	0.0076
4		0.3214	0.1310	0.0571	0.0260	0.0130
5		0.4286	0.1905	0.0857	0.0411	0.0206
6		0.5714	0.2738	0.1286	0.0628	0.0325
7			0.3571	0.1762	0.0887	0.0465
8			0.4524	0.2381	0.1234	0.0660
9			0.5476	0.3048	0.1645	0.0898
10				0.3810	0.2143	0.1201
11				0.4571	0.2684	0.1548
12				0.5429	0.3312	0.1970
13					0.3961	0.2424
14					0.4654	0.2944
15					0.5346	0.3496
16						0.4091
17						0.4686
18						0.5314

$n_2 = 7$							
U_0	n_1						
	1	2	3	4	5	6	7
0	0.1250	0.0278	0.0083	0.0030	0.0013	0.0006	0.0003
1	0.2500	0.0556	0.0167	0.0061	0.0025	0.0012	0.0006
2	0.3750	0.1111	0.0333	0.0121	0.0051	0.0023	0.0012
3	0.5000	0.1667	0.0583	0.0212	0.0088	0.0041	0.0020
4		0.2500	0.0917	0.0364	0.0152	0.0070	0.0035
5		0.3333	0.1333	0.0545	0.0240	0.0111	0.0055
6		0.4444	0.1917	0.0818	0.0366	0.0175	0.0087
7		0.5556	0.2583	0.1152	0.0530	0.0256	0.0131
8			0.3333	0.1576	0.0745	0.0367	0.0189
9			0.4167	0.2061	0.1010	0.0507	0.0265
10			0.5000	0.2636	0.1338	0.0688	0.0364
11				0.3242	0.1717	0.0903	0.0487
12				0.3939	0.2159	0.1171	0.0641
13				0.4636	0.2652	0.1474	0.0825
14				0.5364	0.3194	0.1830	0.1043
15					0.3775	0.2226	0.1297
16					0.4381	0.2669	0.1588
17					0.5000	0.3141	0.1914
18						0.3654	0.2279
19						0.4178	0.2675
20						0.4726	0.3100
21						0.5274	0.3552
22							0.4024
23							0.4508
24							0.5000

(Continuación Tabla A.5)

$n_2 = 8$								
U_0	n_1							
	1	2	3	4	5	6	7	8
0	0.1111	0.0222	0.0061	0.0020	0.0008	0.0003	0.0002	0.0001
1	0.2222	0.0444	0.0121	0.0040	0.0016	0.0007	0.0003	0.0002
2	0.3333	0.0889	0.0242	0.0081	0.0031	0.0013	0.0006	0.0003
3	0.4444	0.1333	0.0424	0.0141	0.0054	0.0023	0.0011	0.0005
4	0.5556	0.2000	0.0667	0.0242	0.0093	0.0040	0.0019	0.0009
5		0.2667	0.0970	0.0364	0.0148	0.0063	0.0030	0.0015
6		0.3556	0.1394	0.0545	0.0225	0.0100	0.0047	0.0023
7		0.4444	0.1879	0.0768	0.0326	0.0147	0.0070	0.0035
8		0.5556	0.2485	0.1071	0.0466	0.0213	0.0103	0.0052
9			0.3152	0.1414	0.0637	0.0296	0.0145	0.0074
10			0.3879	0.1838	0.0855	0.0406	0.0200	0.0103
11			0.4606	0.2303	0.1111	0.0539	0.0270	0.0141
12			0.5394	0.2848	0.1422	0.0709	0.0361	0.0190
13				0.3414	0.1772	0.0906	0.0469	0.0249
14				0.4040	0.2176	0.1142	0.0603	0.0325
15				0.4667	0.2618	0.1412	0.0760	0.0415
16				0.5333	0.3108	0.1725	0.0946	0.0524
17					0.3621	0.2068	0.1159	0.0652
18					0.4165	0.2454	0.1405	0.0803
19					0.4716	0.2864	0.1678	0.0974
20					0.5284	0.3310	0.1984	0.1172
21						0.3773	0.2317	0.1393
22						0.4259	0.2679	0.1641
23						0.4749	0.3063	0.1911
24						0.5251	0.3472	0.2209
25							0.3894	0.2527
26							0.4333	0.2869
27							0.4775	0.3227
28							0.5225	0.3605
29								0.3992
30								0.4392
31								0.4796
32								0.5204

(Continuación Tabla A.5)

[illegible]

(Continuación Tabla A.5)

$n_2 = 10$										
U_0	n_1									
	1	2	3	4	5	6	7	8	9	10
0	0.0909	0.0152	0.0035	0.0010	0.0003	0.0001	0.0001	0.0000	0.0000	0.0000
1	0.1818	0.0303	0.0070	0.0020	0.0007	0.0002	0.0001	0.0000	0.0000	0.0000
2	0.2727	0.0606	0.0140	0.0040	0.0013	0.0005	0.0002	0.0001	0.0000	0.0000
3	0.3636	0.0909	0.0245	0.0070	0.0023	0.0009	0.0004	0.0002	0.0001	0.0000
4	0.4545	0.1364	0.0385	0.0120	0.0040	0.0015	0.0006	0.0003	0.0001	0.0001
5	0.5455	0.1818	0.0559	0.0180	0.0063	0.0024	0.0010	0.0004	0.0002	0.0001
6		0.2424	0.0804	0.0270	0.0097	0.0037	0.0015	0.0007	0.0003	0.0002
7		0.3030	0.1084	0.0380	0.0140	0.0055	0.0023	0.0010	0.0005	0.0002
8		0.3788	0.1434	0.0529	0.0200	0.0080	0.0034	0.0015	0.0007	0.0004
9		0.4545	0.1853	0.0709	0.0276	0.0112	0.0048	0.0022	0.0011	0.0005
10		0.5455	0.2343	0.0939	0.0376	0.0156	0.0068	0.0031	0.0015	0.0008
11			0.2867	0.1199	0.0496	0.0210	0.0093	0.0043	0.0021	0.0010
12			0.3462	0.1518	0.0646	0.0280	0.0125	0.0058	0.0028	0.0014
13			0.4056	0.1868	0.0823	0.0363	0.0165	0.0078	0.0038	0.0019
14			0.4685	0.2268	0.1032	0.0467	0.0215	0.0103	0.0051	0.0026
15			0.5315	0.2697	0.1272	0.0589	0.0277	0.0133	0.0066	0.0034
16				0.3177	0.1548	0.0736	0.0351	0.0171	0.0086	0.0045
17				0.3666	0.1855	0.0903	0.0439	0.0217	0.0110	0.0057
18				0.4196	0.2198	0.1099	0.0544	0.0273	0.0140	0.0073
19				0.4725	0.2567	0.1317	0.0665	0.0338	0.0175	0.0093
20				0.5275	0.2970	0.1566	0.0806	0.0416	0.0217	0.0116
21					0.3393	0.1838	0.0966	0.0506	0.0267	0.0144
22					0.3839	0.2139	0.1148	0.0610	0.0326	0.0177
23					0.4296	0.2461	0.1349	0.0729	0.0394	0.0216
24					0.4765	0.2811	0.1574	0.0864	0.0474	0.0262
25					0.5235	0.3177	0.1819	0.1015	0.0564	0.0315
26						0.3564	0.2087	0.1185	0.0667	0.0376
27						0.3962	0.2374	0.1371	0.0782	0.0446
28						0.4374	0.2681	0.1577	0.0912	0.0526
29						0.4789	0.3004	0.1800	0.1055	0.0615
30						0.5211	0.3345	0.2041	0.1214	0.0716
31							0.3698	0.2299	0.1388	0.0827
32							0.4063	0.2574	0.1577	0.0952
33							0.4434	0.2863	0.1781	0.1088
34							0.4811	0.3167	0.2001	0.1237
35							0.5189	0.3482	0.2235	0.1399
36								0.3809	0.2483	0.1575
37								0.4143	0.2745	0.1763
38								0.4484	0.3019	0.1965
39								0.4827	0.3304	0.2179
40								0.5173	0.3598	0.2406
41									0.3901	0.2644
42									0.4211	0.2894
43									0.4524	0.3153
44									0.4841	0.3421
45									0.5159	0.3697
46										0.3980
47										0.4267
48										0.4559
49										0.4853
50										0.5147

Fuente: cálculos por M. Pagano, Department of Statistics, University of Florida.

Tabla A.6: Valores críticos de T en la prueba del rango signado de Wilcoxon

Unilateral	Bilateral	$n = 5$	$n = 6$	$n = 7$	$n = 8$	$n = 9$	$n = 10$
$P = 0.05$	$P = 0.10$	1	2	4	6	8	11
$P = 0.025$	$P = 0.05$		1	2	4	6	8
$P = 0.01$	$P = 0.02$			0	2	3	5
$P = 0.005$	$P = 0.01$				0	2	3
Unilateral	Bilateral	$n = 11$	$n = 12$	$n = 13$	$n = 14$	$n = 15$	$n = 16$
$P = 0.05$	$P = 0.10$	14	17	21	26	30	36
$P = 0.025$	$P = 0.05$	11	14	17	21	25	30
$P = 0.01$	$P = 0.02$	7	10	13	16	20	24
$P = 0.005$	$P = 0.01$	5	7	10	13	16	19
Unilateral	Bilateral	$n = 17$	$n = 18$	$n = 19$	$n = 20$	$n = 21$	$n = 22$
$P = 0.05$	$P = 0.10$	41	47	54	60	68	75
$P = 0.025$	$P = 0.05$	35	40	46	52	59	66
$P = 0.01$	$P = 0.02$	28	33	38	43	49	56
$P = 0.005$	$P = 0.01$	23	28	32	37	43	49
Unilateral	Bilateral	$n = 23$	$n = 24$	$n = 25$	$n = 26$	$n = 27$	$n = 28$
$P = 0.05$	$P = 0.10$	83	92	101	110	120	130
$P = 0.025$	$P = 0.05$	73	81	90	98	107	117
$P = 0.01$	$P = 0.02$	62	69	77	85	93	102
$P = 0.005$	$P = 0.01$	55	68	68	76	84	92
Unilateral	Bilateral	$n = 29$	$n = 30$	$n = 31$	$n = 32$	$n = 33$	$n = 34$
$P = 0.05$	$P = 0.10$	141	152	163	175	188	201
$P = 0.025$	$P = 0.05$	127	137	148	159	171	183
$P = 0.01$	$P = 0.02$	111	120	130	141	151	162
$P = 0.005$	$P = 0.01$	100	109	118	128	138	149
Unilateral	Bilateral	$n = 35$	$n = 36$	$n = 37$	$n = 38$	$n = 39$	$n = 40$
$P = 0.05$	$P = 0.10$	214	228	242	256	271	287
$P = 0.025$	$P = 0.05$	195	208	222	235	250	264
$P = 0.01$	$P = 0.02$	174	186	198	211	224	238
$P = 0.005$	$P = 0.01$	160	171	183	195	208	221
Unilateral	Bilateral	$n = 41$	$n = 42$	$n = 43$	$n = 44$	$n = 45$	$n = 46$
$P = 0.05$	$P = 0.10$	303	319	336	353	371	389
$P = 0.025$	$P = 0.05$	279	295	311	327	344	361
$P = 0.01$	$P = 0.02$	252	267	281	297	313	329
$P = 0.005$	$P = 0.01$	234	248	262	277	292	307
Unilateral	Bilateral	$n = 47$	$n = 48$	$n = 49$	$n = 50$		
$P = 0.05$	$P = 0.10$	408	427	446	466		
$P = 0.025$	$P = 0.05$	379	397	415	434		
$P = 0.01$	$P = 0.02$	345	362	380	398		
$P = 0.005$	$P = 0.01$	323	339	356	373		

Fuente: Wilcoxon y Wilcoxon (1964).

Tabla A.7: Valores críticos para la estadística de prueba de Kruskal-Wallis

Tamaño de la muestra			Valor	
r_1	r_2	r_3	crítico	α
2	1	1	2.7000	0.500
2	2	1	3.6000	0.200
2	2	2	4.5714	0.067
			3.7143	0.200
3	1	1	3.2000	0.300
3	2	1	4.2857	0.100
			3.8571	0.133
3	2	2	5.3572	0.029
			4.7143	0.048
			4.5000	0.067
			4.4643	0.105
3	3	1	5.1429	0.043
			4.5714	0.100
			4.0000	0.129
3	3	2	6.2500	0.011
			5.3611	0.032
			5.1389	0.061
			4.5556	0.100
			4.2500	0.121
3	3	3	7.2000	0.004
			6.4889	0.011
			5.6889	0.029
			5.6000	0.050
			5.0667	0.086
			4.6222	0.100
4	1	1	3.5714	0.200
4	2	1	4.8214	0.057
			4.5000	0.076
			4.0179	0.114
4	2	2	6.0000	0.014
			5.3333	0.033
			5.1250	0.052
			4.4583	0.100
			4.1667	0.105
4	3	1	5.8333	0.021
			5.2083	0.050
			5.0000	0.057
			4.0556	0.093
			3.8889	0.129
4	3	2	6.4444	0.008
			6.3000	0.011
			5.4444	0.046
			5.4000	0.051
			4.5111	0.098
			4.4444	0.102
4	3	3	6.7455	0.010
			6.7091	0.013
			5.7909	0.046
			5.7273	0.050
			4.7091	0.092
			4.7000	0.101

(Continuación Tabla A.7)

Tamaño de la muestra			Valor	
r_1	r_2	r_3	crítico	α
4	4	1	6.6667	0.010
			6.1667	0.022
			4.9667	0.048
			4.8667	0.054
			4.1667	0.082
			4.0667	0.102
		2	7.0364	0.006
			6.8727	0.011
			5.4545	0.046
			5.2364	0.052
4	4	3	4.5545	0.098
			4.4455	0.103
			7.1439	0.010
			7.1364	0.011
			5.5985	0.049
		4	5.5758	0.051
			4.5455	0.099
			4.4773	0.102
			7.6538	0.008
			7.5385	0.011
5	2	1	5.6923	0.049
			5.6538	0.054
			4.6539	0.097
			4.5001	0.104
			3.8571	0.143
		2	5.2500	0.036
			5.0000	0.048
			4.4500	0.071
			4.2000	0.095
			4.0500	0.119
5	3	1	6.5333	0.008
			6.1333	0.013
			5.1600	0.034
			5.0400	0.056
			4.3733	0.090
		2	4.2933	0.122
			6.4000	0.012
			4.9600	0.048
			4.8711	0.052
			4.0178	0.095
5	3	3	3.8400	0.123
			6.9091	0.009
			6.8218	0.010
			5.2509	0.049
			5.1055	0.052
		4	4.6509	0.091
			4.4945	0.101
			7.0788	0.009
			6.9818	0.011
			5.6485	0.049
5	3	3	5.5152	0.051
			4.5333	0.097
			4.4121	0.109

(Continuación Tabla A.7)

Tamaño de la muestra			Valor	
r_1	r_2	r_3	crítico	α
5	4	1	6.9545	0.008
			6.8400	0.011
			4.9855	0.044
			4.8600	0.056
			3.9873	0.098
		2	3.9600	0.102
			7.2045	0.009
			7.1182	0.010
			5.2727	0.049
			5.2682	0.050
			4.5409	0.098
		3	4.5182	0.101
			7.4449	0.010
			7.3949	0.011
			5.6564	0.049
			5.6308	0.050
5	4	4	4.5487	0.099
			4.5231	0.103
			7.7604	0.009
			7.7440	0.011
			5.6571	0.049
	5	1	5.6176	0.050
			4.6187	0.100
			4.5527	0.102
			7.3091	0.009
			6.8364	0.011
		2	5.1273	0.046
			4.9091	0.053
			4.1091	0.086
			4.0364	0.105
			7.3385	0.010
	5	3	7.2692	0.010
			5.3385	0.047
			5.2462	0.051
			4.6231	0.097
			4.5077	0.100
5	5	4	7.5780	0.010
			7.5429	0.010
			5.7055	0.046
			5.6264	0.051
			4.5451	0.100
	5	5	4.5363	0.102
			7.8229	0.010
			7.7914	0.010
			5.6657	0.049
			5.6429	0.050
	5	5	4.5229	0.099
			4.5200	0.101
			8.0000	0.009
			7.9800	0.010
			5.7800	0.049
			5.6600	0.051
			4.5600	0.100
			4.5000	0.102

Tabla A.8: Valores de Δ^* para determinar el número de replicaciones en un DCA

t	2			3			4		
$1-\beta$	0.7	0.8	0.9	0.7	0.8	0.9	0.7	0.8	0.9
r									
2	4.863	5.653	6.796	4.883	5.570	6.548	4.872	5.504	6.395
3	2.703	3.071	3.589	2.957	3.325	3.838	3.904	3.460	3.967
4	2.104	2.381	2.767	2.335	2.618	3.010	2.468	2.754	3.148
5	1.792	2.024	2.348	1.997	2.236	2.568	2.119	2.362	2.698
6	1.590	1.796	2.081	1.775	1.987	2.280	1.888	2.104	2.401
7	1.446	1.632	1.890	1.615	1.808	2.073	1.719	1.916	2.186
8	1.335	1.507	1.745	1.492	1.670	1.915	1.590	1.771	2.020
9	1.247	1.407	1.629	1.394	1.560	1.788	1.486	1.655	1.888
10	1.175	1.325	1.534	1.313	1.469	1.684	1.400	1.559	1.778
11	1.113	1.256	1.454	1.245	1.393	1.596	1.328	1.479	1.686
12	1.061	1.197	1.385	1.186	1.327	1.521	1.266	1.409	1.607
13	1.016	1.145	1.326	1.135	1.270	1.456	1.211	1.349	1.538
14	0.975	1.100	1.273	1.090	1.220	1.398	1.164	1.296	1.478
15	0.940	1.060	1.226	1.050	1.175	1.347	1.121	1.249	1.424
16	0.908	1.024	1.185	1.015	1.135	1.301	1.083	1.206	1.375
17	0.879	0.991	1.147	0.982	1.099	1.259	1.049	1.168	1.331
18	0.852	0.961	1.112	0.953	1.066	1.222	1.017	1.133	1.292
19	0.828	0.934	1.081	0.926	1.036	1.187	0.988	1.101	1.255
20	0.806	0.909	1.052	0.901	1.008	1.155	0.962	1.071	1.222
21	0.786	0.886	1.025	0.878	0.982	1.126	0.938	1.044	1.191
22	0.767	0.865	1.000	0.857	0.959	1.099	0.915	1.019	1.162
23	0.749	0.845	0.977	0.837	0.936	1.073	0.894	0.996	1.135
24	0.733	0.826	0.956	0.819	0.916	1.050	0.874	0.974	1.110
25	0.717	0.809	0.936	0.802	0.897	1.028	0.856	0.953	1.087

(Continuación Tabla A.8)

t		5			6			7		
r	$1 - \beta$	0.7	0.8	0.9	0.7	0.8	0.9	0.7	0.8	0.9
2		4.889	5.490	6.333	4.922	5.505	6.317	4.963	5.534	6.327
3		3.197	3.562	4.065	3.283	3.647	4.149	3.358	3.723	4.224
4		2.568	2.856	3.251	2.650	2.940	3.337	2.721	3.013	3.412
5		2.211	2.457	2.795	2.287	2.535	2.876	2.352	2.602	2.945
6		1.973	2.191	2.492	2.042	2.264	2.567	2.102	2.326	2.632
7		1.798	1.997	2.271	1.863	2.065	2.341	1.919	2.123	2.401
8		1.664	1.848	2.100	1.725	1.911	2.166	1.777	1.965	2.223
9		1.556	1.728	1.963	1.613	1.787	2.026	1.662	1.839	2.080
10		1.466	1.628	1.850	1.521	1.685	1.910	1.568	1.734	1.961
11		1.391	1.544	1.755	1.443	1.599	1.812	1.488	1.645	1.861
12		1.326	1.472	1.673	1.376	1.524	1.727	1.419	1.569	1.774
13		1.269	1.409	1.602	1.317	1.459	1.654	1.358	1.502	1.699
14		1.220	1.354	1.539	1.266	1.402	1.589	1.305	1.444	1.633
15		1.175	1.305	1.483	1.220	1.351	1.531	1.258	1.391	1.573
16		1.135	1.261	1.432	1.178	1.306	1.479	1.216	1.344	1.520
17		1.099	1.221	1.387	1.141	1.264	1.433	1.177	1.302	1.472
18		1.066	1.184	1.345	1.107	1.226	1.390	1.142	1.263	1.428
19		1.036	1.151	1.307	1.076	1.192	1.351	1.110	1.228	1.388
20		1.009	1.120	1.273	1.047	1.160	1.315	1.081	1.195	1.351
21		0.983	1.092	1.240	1.021	1.131	1.282	1.053	1.165	1.317
22		0.960	1.065	1.210	0.996	1.104	1.251	1.028	1.137	1.285
23		0.938	1.041	1.183	0.973	1.078	1.222	1.004	1.111	1.256
24		0.917	1.018	1.157	0.952	1.055	1.195	0.982	1.086	1.228
25		0.898	0.997	1.132	0.932	1.033	1.170	0.962	1.064	1.203

(Continuación Tabla A.8)

t		8			9			10		
r	$1 - \beta$	0.7	0.8	0.9	0.7	0.8	0.9	0.7	0.8	0.9
2		5.009	5.572	6.350	5.056	5.613	6.382	5.104	5.657	6.419
3		3.426	3.791	4.293	3.488	3.854	4.356	3.545	3.913	4.416
4		2.784	3.078	3.479	2.841	3.136	3.540	2.893	3.191	3.596
5		2.409	2.662	3.008	2.461	2.716	3.064	2.509	2.766	3.116
6		2.155	2.381	2.689	2.203	2.431	2.741	2.247	2.477	2.789
7		1.968	2.174	2.455	2.013	2.221	2.504	2.054	2.263	2.548
8		1.823	2.014	2.274	1.865	2.057	2.319	1.903	2.097	2.361
9		1.706	1.884	2.128	1.746	1.926	2.171	1.782	1.963	2.210
10		1.609	1.777	2.006	1.647	1.816	2.048	1.681	1.852	2.085
11		1.527	1.687	1.904	1.563	1.724	1.943	1.596	1.758	1.979
12		1.457	1.609	1.816	1.491	1.644	1.853	1.522	1.677	1.888
13		1.395	1.540	1.739	1.428	1.575	1.775	1.458	1.606	1.808
14		1.340	1.480	1.671	1.372	1.513	1.706	1.401	1.544	1.738
15		1.292	1.427	1.611	1.323	1.459	1.644	1.351	1.488	1.675
16		1.248	1.379	1.556	1.278	1.410	1.589	1.305	1.438	1.619
17		1.209	1.335	1.507	1.238	1.365	1.539	1.264	1.393	1.568
18		1.173	1.295	1.462	1.201	1.325	1.493	1.227	1.351	1.521
19		1.140	1.259	1.421	1.167	1.288	1.451	1.192	1.314	1.479
20		1.110	1.226	1.384	1.136	1.253	1.413	1.161	1.279	1.440
21		1.082	1.195	1.349	1.108	1.222	1.377	1.131	1.247	1.403
22		1.056	1.166	1.316	1.081	1.193	1.344	1.104	1.217	1.370
23		1.032	1.139	1.286	1.057	1.165	1.313	1.079	1.189	1.338
24		1.009	1.114	1.258	1.033	1.140	1.285	1.056	1.163	1.309
25		0.988	1.091	1.232	1.012	1.116	1.258	1.033	1.139	1.282

(Continuación Tabla A.8)

t		11			13			15		
r	$1 - \beta$	0.7	0.8	0.9	0.7	0.8	0.9	0.7	0.8	0.9
2		5.152	5.702	6.458	5.245	5.792	6.541	5.334	5.879	6.625
3		3.599	3.968	4.472	3.697	4.069	4.576	3.785	4.161	4.670
4		2.942	3.241	3.649	3.030	3.333	3.744	3.109	3.415	3.830
5		2.553	2.812	3.164	2.633	2.895	3.251	2.705	2.970	3.329
6		2.288	2.519	2.834	2.361	2.596	2.914	2.426	2.664	2.986
7		2.091	2.303	2.590	2.160	2.374	2.665	2.220	2.437	2.732
8		1.939	2.134	2.400	2.002	2.201	2.470	2.059	2.260	2.533
9		1.815	1.998	2.247	1.875	2.061	2.313	1.929	2.117	2.372
10		1.713	1.885	2.120	1.770	1.945	2.183	1.820	1.998	2.239
11		1.626	1.790	2.012	1.680	1.847	2.073	1.728	1.897	2.126
12		1.551	1.707	1.920	1.603	1.762	1.977	1.649	1.810	2.028
13		1.486	1.635	1.839	1.536	1.688	1.894	1.580	1.734	1.944
14		1.428	1.572	1.767	1.476	1.622	1.821	1.519	1.667	1.868
15		1.376	1.515	1.704	1.423	1.564	1.755	1.464	1.607	1.801
16		1.330	1.464	1.646	1.375	1.512	1.696	1.415	1.554	1.741
17		1.288	1.418	1.595	1.332	1.464	1.643	1.371	1.505	1.686
18		1.250	1.376	1.547	1.293	1.421	1.594	1.330	1.460	1.636
19		1.215	1.338	1.504	1.257	1.381	1.550	1.293	1.420	1.591
20		1.183	1.302	1.464	1.223	1.345	1.509	1.259	1.382	1.549
21		1.153	1.270	1.427	1.193	1.311	1.471	1.228	1.348	1.510
22		1.126	1.239	1.393	1.164	1.279	1.436	1.198	1.315	1.474
23		1.100	1.211	1.361	1.138	1.250	1.403	1.171	1.285	1.440
24		1.076	1.184	1.332	1.113	1.223	1.373	1.145	1.257	1.409
25		1.053	1.160	1.304	1.090	1.197	1.344	1.122	1.231	1.379

(Continuación Tabla A.8)

t	20			25			30		
$r \backslash 1 - \beta$	0.7	0.8	0.9	0.7	0.8	0.9	0.7	0.8	0.9
2	5.539	6.086	6.829	5.722	6.272	7.018	5.886	6.441	7.191
3	3.977	4.359	4.877	4.138	4.527	5.053	4.279	4.674	5.208
4	3.278	3.592	4.015	3.419	3.739	4.171	3.542	3.868	4.307
5	2.856	3.129	3.497	2.983	3.261	3.637	3.092	3.376	3.758
6	2.565	2.810	3.139	2.681	2.931	3.268	2.780	3.036	3.379
7	2.349	2.572	2.874	2.455	2.684	2.993	2.548	2.781	3.095
8	2.179	2.386	2.666	2.279	2.491	2.777	2.365	2.582	2.874
9	2.042	2.236	2.498	2.136	2.335	2.603	2.217	2.420	2.694
10	1.928	2.111	2.359	2.017	2.205	2.458	2.094	2.286	2.544
11	1.831	2.005	2.240	1.916	2.094	2.335	1.989	2.171	2.417
12	1.747	1.913	2.138	1.829	1.999	2.228	1.899	2.073	2.307
13	1.674	1.833	2.048	1.752	1.916	2.135	1.820	1.986	2.211
14	1.610	1.763	1.969	1.685	1.842	2.053	1.750	1.910	2.126
15	1.552	1.700	1.899	1.625	1.776	1.980	1.687	1.842	2.050
16	1.500	1.643	1.835	1.571	1.717	1.914	1.631	1.781	1.981
17	1.453	1.591	1.778	1.521	1.663	1.854	1.580	1.725	1.920
18	1.410	1.544	1.725	1.477	1.614	1.799	1.534	1.674	1.863
19	1.371	1.502	1.677	1.436	1.569	1.749	1.491	1.628	1.811
20	1.335	1.462	1.633	1.398	1.528	1.703	1.452	1.585	1.764
21	1.302	1.425	1.592	1.363	1.490	1.661	1.416	1.545	1.720
22	1.271	1.391	1.554	1.331	1.454	1.621	1.382	1.509	1.679
23	1.242	1.360	1.519	1.300	1.421	1.584	1.351	1.474	1.641
24	1.215	1.330	1.486	1.272	1.390	1.550	1.321	1.442	1.605
25	1.189	1.302	1.455	1.246	1.361	1.518	1.294	1.412	1.572

Fuente: Bowman y Kastenbaum (1975).

Tabla A.9: Valores de K' para $\beta = 0.80$ $\alpha = 0.05$ para pruebas a una cola, $\alpha = 0.1$ para pruebas a dos colas

d_{f_2}	d_{f_1}											
	1	2	3	4	5	6	8	12	16	24	32	∞
1	13.8	8.52	7.39	6.93	6.68	6.51	6.31	6.13	6.04	5.96	5.92	5.79
2	5.88	3.51	3.02	2.81	2.7	2.62	2.53	2.45	2.41	2.37	2.35	2.30
3	4.3	2.55	2.2	2.03	1.96	1.91	1.85	1.78	1.75	1.72	1.7	1.65
4	3.55	2.1	1.8	1.67	1.6	1.56	1.5	1.45	1.43	1.4	1.39	1.36
5	3.12	1.85	1.58	1.47	1.41	1.37	1.32	1.28	1.25	1.23	1.22	1.18
6	2.81	1.66	1.43	1.32	1.27	1.23	1.19	1.15	1.13	1.11	1.1	1.07
7	2.56	1.52	1.3	1.21	1.16	1.12	1.08	1.05	1.03	1.02	1.01	.979
8	2.37	1.41	1.21	1.12	1.07	1.04	1	.972	.956	.94	.932	.910
9	2.23	1.32	1.14	1.05	1.01	.978	.944	.913	.898	.883	.875	.854
10	2.11	1.25	1.07	.993	.952	.925	.893	.863	.849	.835	.828	.805
12	1.92	1.14	.975	.902	.865	.84	.811	.784	.771	.758	.752	.732
14	1.77	1.05	.899	.831	.797	.775	.748	.723	.71	.699	.693	.676
16	1.65	.976	.838	.775	.743	.722	.697	.673	.662	.651	.646	.631
18	1.56	.921	.79	.731	.701	.681	.658	.635	.624	.614	.609	.594
20	1.48	.873	.75	.693	.665	.646	.624	.602	.592	.583	.578	.563
25	1.32	.779	.669	.619	.593	.577	.557	.538	.529	.52	.515	.502
30	1.2	.708	.608	.563	.54	.525	.507	.489	.481	.473	.469	.456
40	1.04	.613	.526	.486	.467	.454	.438	.423	.416	.409	.405	.395
50	.925	.548	.471	.435	.417	.405	.391	.378	.371	.365	.362	.353
60	.844	.499	.429	.396	.38	.369	.356	.344	.338	.333	.33	.322
80	.73	.432	.371	.342	.328	.319	.308	.298	.292	.288	.285	.278
100	.652	.385	.331	.306	.293	.285	.275	.266	.261	.257	.255	.249

Valores de K' para $\beta = 0.95$ $\alpha = 0.05$ para pruebas a una cola, $\alpha = 0.1$ para pruebas a dos colas (continuación Tabla A.9.)

d_{f_2}	d_{f_1}											
	1	2	3	4	5	6	8	12	16	24	32	∞
1	57.1	19.5	14.4	12.6	11.6	11.0	10.4	9.85	9.58	9.33	9.21	8.86
2	24.2	7.74	5.60	4.77	4.39	4.15	3.86	3.61	3.49	3.38	3.33	3.19
3	17.6	5.58	4.03	3.39	3.13	2.94	2.74	2.55	2.46	2.39	2.35	2.23
4	14.5	4.58	3.28	2.79	2.56	2.40	2.23	2.08	2.01	1.94	1.91	1.82
5	12.6	3.97	2.88	2.41	2.23	2.09	1.93	1.82	1.76	1.69	1.66	1.58
6	11.2	3.55	2.57	2.17	2.00	1.88	1.73	1.82	1.67	1.52	1.49	1.42
7	10.3	3.26	2.36	1.99	1.83	1.72	1.58	1.48	1.43	1.38	1.36	1.30
8	9.70	3.05	2.19	1.86	1.70	1.60	1.48	1.39	1.34	1.29	1.27	1.21
9	9.12	2.87	2.06	1.75	1.60	1.50	1.39	1.30	1.26	1.21	1.19	1.13
10	8.62	2.72	1.95	1.65	1.51	1.42	1.32	1.23	1.19	1.15	1.13	1.07
12	7.83	2.47	1.77	1.50	1.37	1.29	1.20	1.12	1.08	1.04	1.02	.971
14	7.22	2.28	1.63	1.38	1.26	1.19	1.11	1.03	.993	.959	.942	.893
16	6.73	2.13	1.52	1.29	1.18	1.11	1.03	.959	.924	.893	.878	.834
18	6.35	2.01	1.44	1.22	1.11	1.04	.972	.904	.872	.842	.828	.785
20	6.02	1.90	1.36	1.15	1.05	.991	.921	.858	.827	.798	.785	.744
25	5.37	1.70	1.22	1.03	.940	.884	.822	.765	.738	.712	.700	.663
30	4.89	1.54	1.11	.935	.855	.804	.748	.695	.671	.647	.636	.605
40	4.23	1.33	.962	.809	.739	.696	.646	.601	.580	.560	.550	.525
50	3.78	1.19	.854	.722	.661	.622	.577	.537	.518	.500	.492	.469
60	3.45	1.09	.778	.658	.602	.567	.525	.490	.472	.456	.448	.428
80	2.98	.940	.672	.569	.520	.490	.454	.423	.408	.395	.388	.369
100	2.67	.840	.600	.508	.465	.438	.405	.378	.365	.353	.347	.329

Fuente: Harris et al. (1948).

Tabla A.10: Valores de cuantiles superiores de la distribución de la estadística D_n de Kolmogorov - Smirnov

n	$1 - \alpha$				
	0.80	0.85	0.90	0.95	0.99
1	0.900	0.925	0.950	0.975	0.995
2	0.684	0.726	0.776	0.842	0.929
3	0.565	0.597	0.642	0.708	0.828
4	0.494	0.525	0.564	0.624	0.733
5	0.446	0.474	0.510	0.565	0.669
6	0.410	0.436	0.470	0.521	0.618
7	0.381	0.405	0.438	0.486	0.577
8	0.358	0.381	0.411	0.457	0.543
9	0.339	0.360	0.388	0.432	0.514
10	0.322	0.342	0.368	0.410	0.490
11	0.307	0.326	0.352	0.391	0.468
12	0.295	0.313	0.338	0.375	0.450
13	0.284	0.302	0.325	0.361	0.433
14	0.274	0.292	0.314	0.349	0.418
15	0.266	0.283	0.304	0.338	0.404
16	0.258	0.274	0.295	0.328	0.392
17	0.250	0.266	0.286	0.318	0.381
18	0.244	0.259	0.278	0.309	0.371
19	0.237	0.252	0.272	0.301	0.363
20	0.231	0.246	0.264	0.294	0.356
25	0.210	0.220	0.240	0.270	0.320
30	0.190	0.200	0.220	0.240	0.290
35	0.180	0.190	0.210	0.230	0.270
Fórmula para una n mayor	$\frac{1.07}{\sqrt{n}}$	$\frac{1.14}{\sqrt{n}}$	$\frac{1.22}{\sqrt{n}}$	$\frac{1.36}{\sqrt{n}}$	$\frac{1.63}{\sqrt{n}}$

Tabla A.11: Rangos significativos para la prueba del rango múltiple de Duncan

$q(p'; f; 0.01)$												
$p' = \text{número de medias que intervienen en la prueba}$												
f	2	3	4	5	6	7	8	9	10	20	50	100
1	90.00	90	90	90	90	90	90	90	90	90	90	90
2	14.00	14	14	14	14	14	14	14	14	14	14	14
3	8.26	8.5	8.6	8.7	8.8	8.9	8.9	9	9	9.3	9.3	9.3
4	6.51	6.8	6.9	7	7.1	7.1	7.2	7.2	7.3	7.5	7.5	7.5
5	5.7	5.96	6.11	6.18	6.26	6.33	6.4	6.44	6.5	6.8	6.8	6.8
6	5.24	5.51	5.65	5.73	5.81	5.88	5.95	6	6	6.3	6.3	6.3
7	4.95	5.22	5.37	5.45	5.53	5.61	5.69	5.73	5.8	6	6	6
8	4.74	5	5.14	5.23	5.32	5.4	5.47	5.51	5.5	5.8	5.8	5.8
9	4.6	4.86	4.99	5.08	5.17	5.25	5.32	5.36	5.4	5.7	5.7	5.7
10	4.48	4.73	4.88	4.96	5.06	5.13	5.2	5.24	5.28	5.55	5.55	5.55
11	4.39	4.63	4.77	4.86	4.94	5.01	5.06	5.12	5.15	5.39	5.39	5.39
12	4.32	4.55	4.68	4.76	4.84	4.92	4.96	5.02	5.07	5.26	5.26	5.26
13	4.26	4.48	4.62	4.69	4.74	4.84	4.88	4.94	4.98	5.15	5.15	5.15
14	4.21	4.42	4.55	4.63	4.7	4.78	4.83	4.87	4.91	5.07	5.07	5.07
15	4.17	4.37	4.5	4.58	4.64	4.72	4.77	4.81	4.84	5	5	5
16	4.13	4.34	4.45	4.54	4.6	4.67	4.72	4.76	4.79	4.94	4.94	4.94
17	4.1	4.3	4.41	4.5	4.56	4.63	4.68	4.73	4.75	4.89	4.89	4.89
18	4.07	4.27	4.38	4.46	4.53	4.59	4.64	4.68	4.71	4.85	4.85	4.85
19	4.05	4.24	4.35	4.43	4.5	4.56	4.61	4.64	4.67	4.82	4.82	4.82
20	4.02	4.22	4.33	4.4	4.47	4.53	4.58	4.61	4.65	4.79	4.79	4.79
30	3.89	4.06	4.16	4.22	4.32	4.36	4.41	4.45	4.48	4.65	4.71	4.71
40	3.82	3.99	4.1	4.17	4.24	4.3	4.34	4.37	4.41	4.59	4.69	4.69
60	3.76	3.92	4.03	4.12	4.17	4.23	4.27	4.31	4.34	4.53	4.66	4.66
100	3.71	3.86	3.98	4.06	4.11	4.17	4.21	4.25	4.29	4.48	4.64	4.65
∞	3.64	3.8	3.9	3.98	4.04	4.09	4.14	4.17	4.2	4.41	4.6	4.68

(Continuación Tabla A.11)

$q(p'; f; 0.05)$												
p' =número de medias que intervienen en la prueba												
f	2	3	4	5	6	7	8	9	10	20	50	100
1	18	18	18	18	18	18	18	18	18	18	18	18
2	6.09	6.09	6.09	6.09	6.09	6.09	6.09	6.09	6.09	6.09	6.09	6.09
3	4.5	4.5	4.5	4.5	4.5	4.5	4.5	4.5	4.5	4.5	4.5	4.5
4	3.93	4.01	4.02	4.02	4.02	4.02	4.02	4.02	4.02	4.02	4.02	4.02
5	3.64	3.74	3.79	3.83	3.83	3.83	3.83	3.83	3.83	3.83	3.83	3.83
6	3.46	3.58	3.64	3.68	3.68	3.68	3.68	3.68	3.68	3.68	3.68	3.68
7	3.35	3.47	3.54	3.58	3.6	3.61	3.61	3.61	3.61	3.61	3.61	3.61
8	3.26	3.39	3.47	3.52	3.55	3.56	3.56	3.56	3.56	3.56	3.56	3.56
9	3.2	3.34	3.41	3.47	3.5	3.52	3.52	3.52	3.52	3.52	3.52	3.52
10	3.15	3.3	3.37	3.43	3.46	3.47	3.47	3.47	3.47	3.48	3.48	3.48
11	3.11	3.27	3.35	3.39	3.43	3.44	3.45	3.46	3.46	3.48	3.48	3.48
12	3.08	3.23	3.33	3.36	3.4	3.42	3.44	3.44	3.46	3.48	3.48	3.48
13	3.06	3.21	3.3	3.35	3.38	3.41	3.42	3.44	3.45	3.47	3.47	3.47
14	3.03	3.18	3.27	3.33	3.37	3.39	3.41	3.42	3.44	3.47	3.47	3.47
15	3.01	3.16	3.25	3.31	3.36	3.38	3.4	3.42	3.43	3.47	3.47	3.47
16	3	3.15	3.23	3.3	3.34	3.37	3.39	3.41	3.43	3.47	3.47	3.47
17	2.98	3.13	3.22	3.28	3.33	3.36	3.38	3.4	3.42	3.47	3.47	3.47
18	2.97	3.12	3.21	3.27	3.32	3.35	3.37	3.39	3.41	3.47	3.47	3.47
19	2.96	3.11	3.19	3.26	3.31	3.35	3.37	3.39	3.41	3.47	3.47	3.47
20	2.95	3.1	3.18	3.25	3.3	3.34	3.36	3.38	3.4	3.47	3.47	3.47
30	2.89	3.04	3.12	3.2	3.25	3.29	3.32	3.35	3.37	3.47	3.47	3.47
40	2.86	3.01	3.1	3.17	3.22	3.27	3.3	3.33	3.35	3.47	3.47	3.47
60	2.83	2.98	3.08	3.14	3.2	3.24	3.28	3.31	3.33	3.47	3.48	3.48
100	2.8	2.95	3.05	3.12	3.18	3.22	3.26	3.29	3.32	3.47	3.53	3.53
∞	2.77	2.92	3.02	3.09	3.15	3.19	3.23	3.26	3.29	3.47	3.61	3.67

Tabla A.12: Puntos porcentuales del estadístico del rango estudentizado (Student, Newman-Keuls, SNK y Tukey)

f	$q(p_{\alpha}^2; 0.01)$																		
	p																		
	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	90	135	164	186	202	216	227	237	246	253	260	266	272	272	282	286	290	294	298
2	14	19	22.3	24.7	26.6	28.2	29.5	30.7	31.7	32.6	33.4	34.1	34.8	35.4	36	36.5	37	37.5	37.9
3	8.26	10.6	12.2	13.3	14.2	15	15.6	16.2	16.7	17.1	17.5	17.9	18.2	18.5	18.8	19.1	19.3	19.5	19.8
4	6.51	8.12	9.17	9.96	10.6	11.1	11.5	11.9	12.3	12.6	12.8	13.1	13.3	13.5	13.7	13.9	14.1	14.2	14.4
5	5.7	6.97	7.8	8.42	8.91	9.32	9.67	9.97	10.24	10.48	10.7	10.89	11.08	11.24	11.4	11.55	11.68	11.81	11.93
6	5.24	6.33	7.03	7.56	7.97	8.32	8.61	8.87	9.1	9.3	9.49	9.65	9.81	9.95	10.08	10.21	10.32	10.43	10.54
7	4.95	5.92	6.54	7.01	7.37	7.68	7.94	8.17	8.37	8.55	8.71	8.86	9	9.12	9.24	9.35	9.46	9.55	9.65
8	4.74	5.63	6.2	6.63	6.96	7.24	7.47	7.68	7.87	8.03	8.18	8.31	8.44	8.55	8.66	8.76	8.85	8.94	9.03
9	4.6	5.43	5.96	6.35	6.66	6.91	7.13	7.32	7.49	7.65	7.78	7.91	8.03	8.13	8.23	8.32	8.41	8.49	8.57
10	4.48	5.27	5.77	6.14	6.43	6.67	6.87	7.05	7.21	7.36	7.48	7.6	7.71	7.81	7.91	7.99	8.07	8.15	8.22
11	4.39	5.14	5.62	5.97	6.25	6.48	6.67	6.84	6.99	7.13	7.25	7.36	7.46	7.56	7.65	7.73	7.81	7.88	7.95
12	4.32	5.04	5.5	5.84	6.1	6.32	6.51	6.67	6.81	6.94	7.06	7.17	7.26	7.36	7.44	7.52	7.59	7.66	7.73
13	4.26	4.96	5.4	5.73	5.98	6.19	6.37	6.53	6.67	6.79	6.9	7.01	7.1	7.19	7.27	7.34	7.42	7.48	7.55
14	4.21	4.89	5.32	5.63	5.88	6.08	6.26	6.41	6.54	6.66	6.77	6.87	6.96	7.05	7.12	7.2	7.27	7.33	7.39
15	4.17	4.83	5.25	5.56	5.8	5.99	6.16	6.31	6.44	6.55	6.66	6.76	6.84	6.93	7	7.07	7.14	7.2	7.26
16	4.13	4.78	5.19	5.49	5.72	5.92	6.08	6.22	6.35	6.46	6.56	6.66	6.74	6.82	6.9	6.97	07:03	7.09	7.15
17	4.1	4.74	5.14	5.43	5.66	5.85	6.01	6.15	6.27	6.38	6.48	6.57	6.66	6.73	6.8	6.87	6.94	7	7.05
18	4.07	4.7	5.09	5.38	5.6	5.79	5.94	6.08	6.2	6.31	6.41	6.5	6.58	6.65	6.72	6.79	6.85	6.91	6.96
19	4.05	4.67	5.05	5.33	5.55	5.73	5.89	6.02	6.14	6.25	6.34	6.43	6.51	6.58	6.65	6.72	6.78	6.84	6.89
20	4.02	4.64	5.02	5.29	5.51	5.69	5.84	5.97	6.09	6.19	6.29	6.37	6.45	6.52	6.59	6.65	6.71	6.76	6.82
24	3.96	4.54	4.91	5.17	5.37	5.54	5.69	5.81	5.92	6.02	6.11	6.19	6.26	6.33	6.39	6.45	6.51	6.56	6.61
30	3.89	4.45	4.8	5.05	5.24	5.4	5.54	5.65	5.76	5.85	5.93	6.01	6.08	6.14	6.2	6.26	6.31	6.36	6.41
40	3.82	4.37	4.7	4.93	5.11	5.27	5.39	5.5	5.6	5.69	5.77	5.84	5.9	5.96	6.02	6.07	6.12	6.17	6.21
60	3.76	4.28	4.6	4.82	4.99	5.13	5.25	5.36	5.45	5.53	5.6	5.67	5.73	5.79	5.84	5.89	5.93	5.98	6.02
120	3.7	4.2	4.5	4.71	4.87	5.01	5.12	5.21	5.3	5.38	5.44	5.51	5.56	5.61	5.66	5.71	5.75	5.79	5.83
∞	3.64	4.12	4.4	4.6	4.76	4.88	4.99	5.08	5.16	5.23	5.29	5.35	5.4	5.45	5.49	5.54	5.57	5.61	5.65

(Continuación Tabla A.12)

$q(p;f;0.05)$																				
p																				
f	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	
1	18.1	26.7	32.8	37.2	40.5	43.1	45.4	47.3	49.1	50.6	51.9	53.2	54.3	55.4	56.3	57.2	58	58.8	59.6	
2	6.09	8.28	9.8	10.89	11.73	12.43	13.03	13.54	13.99	14.39	14.75	15.08	15.38	15.65	15.91	16.14	16.36	16.57	16.77	
3	4.5	5.88	6.83	7.51	8.04	8.47	8.85	9.18	9.46	9.72	9.95	10.16	10.35	10.52	10.69	10.84	10.98	11.12	11.24	
4	3.93	5	5.76	6.31	6.73	7.06	7.35	7.6	7.83	8.03	8.21	8.37	8.52	8.67	8.8	8.92	9.03	9.14	9.24	
5	3.64	4.6	5.22	5.67	6.03	6.33	6.58	6.8	6.99	7.17	7.32	7.47	7.6	7.72	7.83	7.93	8.03	8.12	8.21	
6	3.46	4.34	4.9	5.31	5.63	5.89	6.12	6.32	6.49	6.65	6.79	6.92	7.04	7.14	7.24	7.34	7.43	7.51	7.59	
7	3.34	4.16	4.68	5.06	5.35	5.59	5.8	5.99	6.15	6.29	6.42	6.54	6.65	6.75	6.84	6.93	7.01	7.08	7.16	
8	3.26	4.04	4.53	4.89	5.17	5.4	5.6	5.77	5.92	6.05	6.18	6.29	6.39	6.48	6.57	6.65	6.73	6.8	6.87	
9	3.2	3.95	4.42	4.76	5.02	5.24	5.43	5.6	5.74	5.87	5.98	6.09	6.19	6.28	6.36	6.44	6.51	6.58	6.65	
10	3.15	3.88	4.33	4.66	4.91	5.12	5.3	5.46	5.6	5.72	5.83	5.93	6.03	6.12	6.2	6.27	6.34	6.41	6.47	
11	3.11	3.82	4.26	4.58	4.82	5.03	5.2	5.35	5.49	5.61	5.71	5.81	5.9	5.98	6.06	6.14	6.2	6.27	6.33	
12	3.08	3.77	4.2	4.51	4.75	4.95	5.12	5.27	5.4	5.51	5.61	5.71	5.8	5.88	5.95	6.02	6.09	6.15	6.21	
13	3.06	3.73	4.15	4.46	4.69	4.88	5.05	5.19	5.32	5.43	5.53	5.63	5.71	5.79	5.86	5.93	6	6.06	6.11	
14	3.03	3.7	4.11	4.41	4.64	4.83	4.99	5.13	5.25	5.36	5.46	5.56	5.64	5.72	5.79	5.86	5.92	5.98	6.03	
15	3.01	3.67	4.08	4.37	4.59	4.78	4.94	5.08	5.2	5.31	5.4	5.49	5.57	5.65	5.72	5.79	5.85	5.91	5.96	
16	3	3.65	4.05	4.34	4.56	4.74	4.9	5.03	5.15	5.26	5.35	5.44	5.52	5.59	5.66	5.73	5.79	5.84	5.9	
17	2.98	3.62	4.02	4.31	4.52	4.7	4.86	4.99	5.11	5.21	5.31	5.39	5.47	5.55	5.61	5.68	5.74	5.79	5.84	
18	2.97	3.61	4	4.28	4.49	4.67	4.83	4.96	5.07	5.17	5.27	5.35	5.43	5.5	5.57	5.63	5.69	5.74	5.79	
19	2.96	3.59	3.98	4.26	4.47	4.64	4.79	4.92	5.04	5.14	5.23	5.32	5.39	5.46	5.53	5.59	5.65	5.7	5.75	
20	2.95	3.58	3.96	4.24	4.45	4.62	4.77	4.9	5.01	5.11	5.2	5.28	5.36	5.43	5.5	5.56	5.61	5.66	5.71	
24	2.92	3.53	3.9	4.17	4.37	4.54	4.68	4.81	4.92	5.01	5.1	5.18	5.25	5.32	5.38	5.44	5.5	5.55	5.59	
30	2.89	3.48	3.84	4.11	4.3	4.46	4.6	4.72	4.83	4.92	5	5.08	5.15	5.21	5.27	5.33	5.38	5.43	5.48	
40	2.86	3.44	3.79	4.04	4.23	4.39	4.52	4.63	4.74	4.82	4.9	4.98	5.05	5.11	5.17	5.22	5.27	5.32	5.36	
60	2.83	3.4	3.74	3.98	4.16	4.31	4.44	4.55	4.65	4.73	4.81	4.88	4.94	5	5.06	5.11	5.15	5.2	5.24	
120	2.8	3.36	3.69	3.92	4.1	4.24	4.36	4.47	4.56	4.64	4.71	4.78	4.84	4.9	4.95	5	5.04	5.09	5.13	
∞	2.77	3.32	3.63	3.86	4.03	4.17	4.29	4.39	4.47	4.55	4.62	4.68	4.74	4.8	4.84	4.98	4.93	4.97	5.01	

Fuente: Pearson y Hartley (1954).

Tabla A.13: Valores críticos para la prueba de Dunnett para comparar tratamientos con un control

$d_{(p;f;0.05)}$									
Comparaciones de dos colas									
p = número de medias de tratamientos (sin incluir el control)									
f	1	2	3	4	5	6	7	8	9
5	2.57	3.03	3.29	3.48	3.62	3.73	3.82	3.9	3.97
6	2.45	2.86	3.1	3.26	3.39	3.49	3.57	3.64	3.71
7	2.36	2.75	2.97	3.12	3.24	3.33	3.41	3.47	3.53
8	2.31	2.67	2.88	3.02	3.13	3.22	3.29	3.35	3.41
9	2.26	2.61	2.81	2.95	3.05	3.14	3.2	3.26	3.32
10	2.23	2.57	2.76	2.89	2.99	3.07	3.14	3.19	3.24
11	2.2	2.53	2.72	2.84	2.94	3.02	3.08	3.14	3.19
12	2.18	2.5	2.68	2.81	2.9	2.98	3.04	3.09	3.14
13	2.16	2.48	2.65	2.78	2.87	2.94	3	3.06	3.1
14	2.14	2.46	2.63	2.75	2.84	2.91	2.97	3.02	3.07
15	2.13	2.44	2.61	2.73	2.82	2.89	2.95	3	3.04
16	2.12	2.42	2.59	2.71	2.8	2.87	2.92	2.97	3.02
17	2.11	2.41	2.58	2.69	2.78	2.85	2.9	2.95	3
18	2.1	2.4	2.56	2.68	2.76	2.83	2.89	2.94	2.98
19	2.09	2.39	2.55	2.66	2.75	2.81	2.87	2.92	2.96
20	2.09	2.38	2.54	2.65	2.73	2.8	2.86	2.9	2.95
24	2.06	2.35	2.51	2.61	2.7	2.76	2.81	2.86	2.9
30	2.04	2.32	2.47	2.58	2.66	2.72	2.77	2.82	2.86
40	2.02	2.29	2.44	2.54	2.62	2.68	2.73	2.77	2.81
60	2	2.27	2.41	2.51	2.58	2.64	2.69	2.73	2.77
120	1.98	2.24	2.38	2.47	2.55	2.6	2.65	2.69	2.73
∞	1.96	2.21	2.35	2.44	2.51	2.57	2.61	2.65	2.69

(Continuación Tabla A.13)

$d_{(p;f;0.01)}$									
Comparaciones de dos colas									
p = número de medias de tratamientos (sin incluir el control)									
f	1	2	3	4	5	6	7	8	9
5	4.03	4.63	4.98	5.22	5.41	5.56	5.69	5.8	5.89
6	3.71	4.21	4.51	4.71	4.87	5	5.1	5.2	5.28
7	3.5	3.95	4.21	4.39	4.53	4.64	4.74	4.82	4.89
8	3.36	3.77	4	4.17	4.29	4.4	4.48	4.56	4.62
9	3.25	3.63	3.85	4.01	4.12	4.22	4.3	4.37	4.43
10	3.17	3.53	3.74	3.88	3.99	4.08	4.16	4.22	4.28
11	3.11	3.45	3.65	3.79	3.89	3.98	4.05	4.11	4.16
12	3.05	3.39	3.58	3.71	3.81	3.89	3.96	4.02	4.07
13	3.01	3.33	3.52	3.65	3.74	3.82	3.89	3.94	3.99
14	2.98	3.29	3.47	3.59	3.69	3.76	3.83	3.88	3.93
15	2.95	3.25	3.43	3.55	3.64	3.71	3.78	3.83	3.88
16	2.92	3.22	3.39	3.51	3.6	3.67	3.73	3.78	3.83
17	2.9	3.19	3.36	3.47	3.56	3.63	3.69	3.74	3.79
18	2.88	3.17	3.33	3.44	3.53	3.6	3.66	3.71	3.75
19	2.86	3.15	3.31	3.42	3.5	3.57	3.63	3.68	3.72
20	2.85	3.13	3.29	3.4	3.48	3.55	3.6	3.65	3.69
24	2.8	3.07	3.22	3.32	3.4	3.47	3.52	3.57	3.61
30	2.75	3.01	3.15	3.25	3.33	3.39	3.44	3.49	3.52
40	2.7	2.95	3.09	3.19	3.26	3.32	3.37	3.41	3.44
60	2.66	2.9	3.03	3.12	3.19	3.25	3.29	3.33	3.37
120	2.62	2.85	2.97	3.06	3.12	3.18	3.22	3.26	3.29
∞	2.58	2.79	2.92	3	3.06	3.11	3.15	3.19	3.22

(Continuación Tabla A.13)

$d_{(p;f;0.05)}$									
Comparaciones de una cola									
$p = \text{número de medias de tratamientos (sin incluir el control)}$									
f	1	2	3	4	5	6	7	8	9
5	2.02	2.44	2.68	2.85	2.98	3.08	3.16	3.24	3.3
6	1.94	2.34	2.56	2.71	2.83	2.92	3	3.07	3.12
7	1.89	2.27	2.48	2.62	2.73	2.82	2.89	2.95	3.01
8	1.86	2.22	2.42	2.55	2.66	2.74	2.81	2.87	2.92
9	1.83	2.18	2.37	2.5	2.6	2.68	2.75	2.81	2.86
10	1.81	2.15	2.34	2.47	2.56	2.64	2.7	2.76	2.81
11	1.8	2.13	2.31	2.44	2.53	2.6	2.67	2.72	2.77
12	1.78	2.11	2.29	2.41	2.5	2.58	2.64	2.69	2.74
13	1.77	2.09	2.27	2.39	2.48	2.55	2.61	2.66	2.71
14	1.76	2.08	2.25	2.37	2.46	2.53	2.59	2.64	2.69
15	1.75	2.07	2.24	2.36	2.44	2.51	2.57	2.62	2.67
16	1.75	2.06	2.23	2.34	2.43	2.5	2.56	2.61	2.65
17	1.74	2.05	2.22	2.33	2.42	2.49	2.54	2.59	2.64
18	1.73	2.04	2.21	2.32	2.41	2.48	2.53	2.58	2.62
19	1.73	2.03	2.2	2.31	2.4	2.47	2.52	2.57	2.61
20	1.72	2.03	2.19	2.3	2.39	2.46	2.51	2.56	2.6
24	1.71	2.01	2.17	2.28	2.36	2.43	2.48	2.53	2.57
30	1.7	1.99	2.15	2.25	2.33	2.4	2.45	2.5	2.54
40	1.68	1.97	2.13	2.23	2.31	2.37	2.42	2.41	2.51
60	1.67	1.95	2.1	2.21	2.28	2.35	2.39	2.44	2.48
120	1.66	1.93	2.08	2.18	2.26	2.32	2.37	2.41	2.45
∞	1.64	1.92	2.06	2.16	2.23	2.29	2.34	2.38	2.42

(Continuación Tabla A.13)

$d_{(p;f;0.01)}$									
Comparaciones de una cola									
p = número de medias de tratamientos (sin incluir el control)									
f	1	2	3	4	5	6	7	8	9
5	3.37	3.9	4.21	4.43	4.6	4.73	4.85	4.94	5.03
6	3.14	3.61	3.88	4.07	4.21	4.33	4.43	4.51	4.59
7	3	3.42	3.66	3.83	3.96	4.07	4.15	4.23	4.3
8	2.9	3.29	3.51	3.67	3.79	3.88	3.96	4.03	4.09
9	2.82	3.19	3.4	3.55	3.66	3.75	3.82	3.89	3.94
10	2.76	3.11	3.31	3.45	3.56	3.64	3.71	3.78	3.83
11	2.72	3.06	3.25	3.38	3.48	3.56	3.63	3.69	3.74
12	2.68	3.01	3.19	3.32	3.42	3.5	3.56	3.62	3.67
13	2.65	2.97	3.15	3.27	3.37	3.44	3.51	3.56	3.61
14	2.62	2.94	3.11	3.23	3.32	3.4	3.46	3.51	3.56
15	2.6	2.91	3.08	3.2	3.29	3.36	3.42	3.47	3.52
16	2.58	2.88	3.05	3.17	3.26	3.33	3.39	3.44	3.48
17	2.57	2.86	3.03	3.14	3.23	3.3	3.36	3.41	3.45
18	2.55	2.84	3.01	3.12	3.21	3.27	3.33	3.38	3.42
19	2.54	2.83	2.99	3.1	3.18	3.25	3.31	3.36	3.4
20	2.53	2.81	2.97	3.08	3.17	3.23	3.29	3.34	3.38
24	2.49	2.77	2.92	3.03	3.11	3.17	3.22	3.27	3.31
30	2.46	2.72	2.87	2.97	3.05	3.11	3.16	3.21	3.24
40	2.42	2.68	2.82	2.92	2.99	3.05	3.1	3.14	3.18
60	2.39	2.64	2.78	2.87	2.94	3	3.04	3.08	3.12
120	2.36	2.6	2.73	2.82	2.89	2.94	2.99	3.03	3.06
∞	2.33	2.56	2.68	2.77	2.84	2.89	2.93	2.97	3

Tabla A.14: Valores críticos de la estadística de Spearman.

r	0.001	0.005	0.010	0.025	0.050	0.100
4	—	—	—	—	0.8000	0.8000
5	—	—	0.9000	0.9000	0.8000	0.7000
6	—	0.9429	0.8857	0.8286	0.7714	0.6000
7	0.9643	0.8929	0.8571	0.7450	0.6786	0.5357
8	0.9286	0.8571	0.8095	0.7143	0.6190	0.5000
9	0.9000	0.8167	0.7667	0.6833	0.5833	0.4667
10	0.8667	0.7818	0.7333	0.6364	0.5515	0.4424
11	0.8364	0.7545	0.7000	0.6091	0.5273	0.4182
12	0.8182	0.7273	0.6713	0.5804	0.4965	0.3986
13	0.7912	0.6978	0.6429	0.5549	0.4780	0.3791
14	0.7670	0.6747	0.6220	0.5341	0.4593	0.3626
15	0.7464	0.6536	0.6000	0.5179	0.4429	0.3500
16	0.7265	0.6324	0.5824	0.5000	0.4265	0.3382
17	0.7083	0.6152	0.5637	0.4853	0.4118	0.3260
18	0.6904	0.5975	0.5480	0.4716	0.3994	0.3148
19	0.6737	0.5825	0.5333	0.4579	0.3895	0.3070
20	0.6586	0.5684	0.5203	0.4451	0.3789	0.2977
21	0.6455	0.5545	0.5078	0.4351	0.3688	0.2909
22	0.6318	0.5426	0.4963	0.4241	0.3597	0.2829
23	0.6186	0.5306	0.4852	0.4150	0.3518	0.2767
24	0.6070	0.5200	0.4748	0.4061	0.3435	0.2704
25	0.5962	0.5100	0.4654	0.3977	0.3362	0.2646
26	0.5856	0.5002	0.4564	0.3894	0.3299	0.2588
27	0.5757	0.4915	0.4481	0.3822	0.3236	0.2540
28	0.5660	0.4828	0.4401	0.3749	0.3175	0.2490
29	0.5567	0.4744	0.4320	0.3685	0.3113	0.2443
30	0.5479	0.4665	0.4251	0.3620	0.3059	0.2400

Valores críticos aproximados de r_s^* del extremo superior de la curva, donde $P(r > r_s^*) \leq \alpha$, $r = 4(1)30$, nivel de significancia α .










Figura A.1: Curvas de operación característica para el análisis de varianza del modelo con efectos fijos.



(Continuación Figura A.1)



(Continuación Figura A.1)



(Continuación Figura A.1)










Figura A.2: Curvas de operación característica para el análisis de varianza del modelo con efectos aleatorios.



(Continuación Figura A.2)



(Continuación Figura A.2)



(Continuación Figura A.2)

Bibliografía

- Acosta, M. E. (1999), Algoritmos de cómputo para la construcción de diseños factoriales fraccionados 2^{k-p} , Trabajo de grado, Universidad Nacional de Colombia, Bogotá.
- Anscombe, F. J. (1947), 'The Validity of Comparative Experiments', *Journal Royal of the Statistical Society* **61**, 181–211.
- Aranda-Ordaz, F. J. (1981), 'On two families of transformations to additivity for binary response data', *Biometrika* **68**, 357–363.
- Bartlett, M. S. (1937), 'Properties of Sufficiency and Statistical Tests', *Proceedings of the Royal Society of London, Series A* **160**(901), 268–282.
- Bartlett, M. S. (1947), 'The Use of Transformations', *Biometrics* **3**(1), 39–52.
- Bhattacharya, G. & Johnson, R. (1977), *Statistical Concepts and Methods*, John Wiley & Sons, New York.
- Bowman, K. & Kastenbaum, M. A. (1975), 'Sample Size Requirement: Single and Double Classification Experiments', *In Selected Tables in Mathematical Statistics. (Harter, H. L. and Owen, I. B. eds.)* **III**, 111–232.
- Box, G. E. P. (1952), 'Multi-factor Designs of First Order', *Biometrika* **39**(1), 49–57.
- Box, G. E. P. (1954), 'Some Theorems on Quadratic Forms Applied in the Study of Analysis of Variance Problems, ii. Effects of Inequality of Variance and of Correlation Between Errors in the Two-Way Classification', *The Annals of Mathematical Statistics* **25**, 484–498.
- Box, G. E. P. (1957), Integration of Techniques in Process Development, Technical Report, Statistical Techniques Research Group.
- Box, G. E. P. & Anderson, S. C. (1955), 'Non-normality and Test on Variance', *Biometrika* **40**(3/4), 318–335.

- Box, G. E. P. & Cox, D. R. (1964), 'An Analysis of Transformations', *Journal of the Royal Statistical Society, Series B* **26**(2), 211–252.
- Box, G. E. P. & Hunter, J. S. (1957), 'Multi-Factor Experimental Designs for Exploring Response Surfaces', *Annals of Mathematical Statistics* **28**(1), 195–241.
- Box, G. E. P. & Hunter, J. S. (1961), 'The 2^{k-p} Fractional Factorial Designs I', *Tecnometrics* **3**, 311–351.
- Box, G. E. P. & Wilson, K. B. (1951), 'On the Experimental Attainment of the Optimum Conditions', *Journal Royal of the Statistical Society* **13**, 1–45.
- Box, G. E. P., Hunter, W. G. & Hunter, J. S. (1978), *Statistics for Experimenters*, John Wiley & Sons, New York.
- Bradley, E. L. & Blackwood, L. G. (1989), 'Comparing Paired Data: A Simultaneous Test for Means and Variances', *The American Statistician* **43**(4), 234–235.
- Brown, H. & Prescott, R. (1999), *Applied Mixed Models in Medicine*, John Wiley & Sons, New York.
- Brownlee, K. A. (1957), 'The Principles of Experimental Design', *Industrial Quality Control* **13**, 1–9.
- Cochran, W. G. & Cox, G. M. (1957), *Experimental Designs*, Second Edition, John Wiley & Sons, New York.
- Cochran, W. G. & Cox, G. M. (1974), *Diseños experimentales*, Editorial Trillas, México.
- Conover, W. J. (1980), *Practical Nonparametric Statistics*, John Wiley & Sons, New York.
- Conover, W. J., Johnson, M. E. & Johnson, M. M. (1981), 'A Comparative Study of Tests for Homogeneity of Variances, with Applications to the Outer Continental Shelf Bidding Data', *Technometrics* **23**(4), 351–361.
- Corzo, J. A. (2005), Notas de clase: estadística no paramétrica-métodos basados en rangos, Technical report, Facultad de Ciencias, Universidad Nacional de Colombia, Bogotá, D.C.
- De Campos, H. (1984), *Estatística aplicada a' experimentação com cana de açúcar*, FEALq USP, São Paulo.

- Del Castillo, E. & Montgomery, D. C. (1993), 'A Nonlinear Programming Solution to the Dual Response Problem', *Journal of Quality Technology* **25**(3), 199–204.
- Derringer, G. C. (1969), 'Sequential Methods for Estimating Response Surfaces', *Industrial and Engineering Chemistry* **61**(12), 6–13.
- Derringer, G. C. & Suich, R. (1980), 'Simultaneous Optimization of Several Responses Variables', *Journal of Quality Technology* **12**(4), 214–219.
- Díaz, L. G. (2002), *Estadística multivariada: inferencia y métodos*, Universidad Nacional de Colombia, Bogotá, D.C.
- Dobson, A. J. (2002), *An Introduction to Generalized Linear Models*, Chapman & Hall.
- Dobson, A. J. (2008), *An Introduction to Generalized Linear Models*, Chapman and Hall.
- Draper, N. R. & Smith, H. (1998), *Applied Regression Analysis*, Third Edition. John Wiley & Sons, New York.
- Dunnnett, C. W. (1955), 'A Multiple Comparisons Procedure for Comparing Several Treatments with a Control', *Journal of the American Statistical Association* **50**(272), 1096–1121.
- Eisenhart, C. (1947), 'The Assumptions Underlying the Analysis of Variance', *Biometrics* **3**, 1–21.
- Federer, W. (1955), *Experimental Design; Theory and Application*, Vol. 14, Oxford.
- Finney, D. J. (1945), 'The Fractional Replication of Factorial Experiments', *Annals Eugenics* **12**, 291–301.
- Finney, D. J. (1946), 'Recent Developments in the Design of Field Experiments III Fractional Replication', *Journal Agriculture Science* **36**(3), 184–191.
- Finney, D. J. (1955), *An Introduction to the Theory of Experimental Design*, The University of Chicago Press, Chicago.
- Fisher, R. A. (1935), *The Design of Experiments*, Oliver & Boyd, Edinburgh.

- Fisher, R. A. (1945), 'A System of Confounding for Factors with More than two Alternatives, Giving Completely Orthogonal Cubes and Higher Powers', *Annals of Human Genetics* **12**(1), 283–290.
- Fisher, R. A. & Yates, F. (1957), *Statistical Tables for Biological, Agricultural and Medical Research*, 5th edition. Hafner Public Co., Inc., New York.
- Gardiner, D. A., Grandage, A. H. & Hader, R. J. (1959), 'Third order rotatable designs for exploring response surfaces', *The Annals of Mathematical Statistics* **30**(4), 1082–1096.
- Gill, J. L. (1978), *Design and Analysis of Experiments in the Animal and Medical Sciences*, Iowa State University Press, Ames, Iowa.
- González, L. M. (1997), Ajuste de bloques incompletos mediante el procedimiento IML de SAS, Trabajo de grado, Universidad Nacional de Colombia, Bogotá.
- Goodnight, J. H. (1980), 'Tests of hypotheses in fixed effects linear models', *Communications in Statistics - Theory and Methods* **9**(2), 167–180.
- Graybill, F. A. (1976), *Theory and Application of the Linear Model*, North Scituate, MA: Duxbury Press, Boston.
- Harrington, J. E. C. (1965), 'The Desirability Function', *Industrial Quality Control* **21**(10), 494–498.
- Harris, M., Horvitz, D. G. & Mood, A. M. (1948), 'On the Determination of Sample Sizes in Designing Experiments', *Journal of the American Statistical Association* **43**(243), 391–402.
- Hartley, H. O. (1950), 'The Maximum F-Ratio as a Short-Cut Test for Heterogeneity of Variance', *Biometrika* **37**(3/4), 308–312.
- Henderson, C. R. (1953), 'Estimation of Variance and Covariance Components', *Biometrics* **9**(2), 226–252.
- Henderson, C. R. (1984), *Application of Linear Models in Animal Breeding*, University of Guelph, Guelph, Ontario.
- Hinde, J. & Demétrio, C. G. B. (1998), 'Overdispersion: Models and estimation', *Computational Statistics & Data Analysis* **27**(2), 151–170.
- Hinkelman, K. & Kempthorne, O. (1994), *Design and Analysis of Experiments Vol I. Introduction to Experimental Design*, John Wiley & Sons, New York.

- Hinkelmann, K. & Kempthorne, O. (2005), *Advanced Experimental Design*, John Wiley & Sons, New York.
- Hinkelmann, K. & Kempthorne, O. (2007), *Design and Analysis of Experiments Vol I. Introduction to Experimental Design*, second edn, John Wiley & Sons, New York.
- Hinkelmann, K. (2012), *Design and Analysis of Experiments*, Vol. 3 of *Special Designs and Applications*, Wiley, Hoboken, New York.
- Hinkelmann, K. & Kempthorne, O. (1994), *Design and Analysis of Experiments*, Vol. 1 of *Introduction to Experimental Design*, Wiley, Hoboken, New York.
- Hinkelmann, K. & Kempthorne, O. (2005), *Design and Analysis of Experiments*, Vol. 2 of *Advanced Experimental Design*, Wiley, Hoboken, New York.
- Hocking, R. R. (1985), *The Analysis of Linear Models*, Belmont, CA: Brooks/Cole Publishing Co, Monterrey.
- Hocking, R. R. & Speed, F. M. (1975), 'A Full Rank Analysis of Some Linear Model Problems', *Journal of the American Statistical Association* **70**, 706–712.
- Hodges, J. L. & Lehmann, E. L. (1963), 'Estimates of Location Based on Rank Test', *Annals of Mathematical Statistics* **34**(2), 598–611.
- Iemma, A. F. (1993), *Análisis de varianza de experimentos con celdas vacías*, Escuela Superior De Agricultura "Luiz De Queiroz". Universidade De São Paulo, São Paulo, chapter II, III, V.
- Iemma, A. F., López, L. A. & Rincón, L. F. (1999), 'Proyectores ortogonales esperados', *Revista Investigación Operacional* **20**, 107–114.
- Jarque, C. M. & Bera, A. K. (1987), 'A Test for Normality of Observations and Regression Residuals', *International Statistical Review* **55**, 163–172.
- John, P. W. M. (1971), *Incomplete Block Design*, Marcel Dekker, New York and Basel.
- Jørgensen, B. (1993), *The Theory of Linear Models*, Chapman-Hall, New York.
- Kempthorne, O. (1952), *The Design and Analysis of Experiments*, John Wiley & Sons, New York.

- Kenett, R. S. & Zacks, S. (2000), *Estadística industrial moderna: diseño y control de la calidad y la confiabilidad*, Internacional Thompson Editores, S. A., México.
- Keuls, M. (1952), 'The Use of the "Studentized Range" in Connection with an Analysis of Variance', *Euphytica* **1**(2), 112–122.
- Khuri, A. I. & Colon, M. (1981), 'Simultaneous Optimization of Multiples Responses Represented by Polynomial Regression Functions', *Technometrics* **23**(4), 363–375.
- Khuri, A. I. & Cornell, J. A. (1987), *Response Surfaces: Designs an Analysis*, Marcel Dekker, New York.
- Koopmans, H. S. & Sclafani, A. (1981), 'Control of body weight by lower gut signals', *International Journal of Obesity* **5**(5), 491–495.
- Kruskal, W. H. & Wallis, W. A. (1952), 'Use of Ranks in One-criterion Variance Analysis', *Journal of the American Statistical Association* **47**, 583–621.
- Kuehl, R. O. (2001), *Diseño de experimentos. principios estadísticos para el diseño y análisis de investigaciones*, 2da edición, Thomson, México.
- Law, A. M. & Kelton, W. D. (1991), *Simulation Modeling and Analysis*, 2nd ed. McGraw-Hill, New York.
- Levene, H. (1960), *Robust Tests for Equality of Variance*, Stanford University Press, Palo Alto, CA, pp. 278–292.
- Lewis, S. L., Montgomery, D. C. & Myers, R. H. (2001a), 'Confidence interval coverage for designated experiments analyzed with glms', *Journal of Quality Technology* **33**(3), 279–292.
- Lewis, S. L., Montgomery, D. C. & Myers, R. H. (2001b), 'Examples of designed experiments with nonnormal responses', *Journal of Quality Technology* **33**(3), 265–278.
- Lin, D. K. J. & Tu, W. (1995), 'Dual Response Surface Optimization', *Journal of Quality Technology* **27**(1), 34–39.
- Mann, H. B. & Whitney, D. R. (1947), 'On a Test of Whether One of Two Randon Variables is Stochastically Larger Than the Other', *Annals of Mathematical Statistics* **18**(1), 50–60.

- Martin, F. G. (1989), *Statistical Design and Analysis of Experiments*, Technical report, University of Florida Gainesville, Florida.
- Martínez, A. (1972), *Diseño y análisis de experimentos con caña de azúcar*, Colegio de Postgraduados, Chapingo, México.
- Martínez, A. (1981), *Diseños experimentales*, CEC-CP, México.
- Martínez, A. (1988), *Diseños experimentales. Métodos y elementos de teoría*, Trillas, México.
- McCullagh, P. & Nelder, J. (1989), *Generalized Linear Models*, Chapman Hall, London.
- McLean, R. A. & Anderson, V. L. (1984), *Applied Factorial and Fractional Design*, Marcel Dekker, Inc, New York.
- Melo, O. O., Lozano, A. R. & López, L. A. (1999), 'Funciones Estimables en Modelos de Clasificación con Datos Desbalanceados a través del Algoritmo de Cholesky', *Revista Multiciências* **3**(2), 131–147.
- Mendenhall, W. (1968), *Introduction to Linear Models and the Design and Analysis of Experiments*, Duxbury Press, Belmont.
- Méndez, I. (1981), Algunos aspectos del diseño experimental, in 'IIMAS-UNAM', Comunicaciones, México.
- Méndez, I. (1993), Diseño de experimentos, in 'Memorias del X Coloquio Distrital de Matemáticas y Estadística', Bogotá.
- Miller, B. (1986), *Anova Basics of Applied Statistics*, John Wiley & Sons, New York.
- Montgomery, D. C. (1984), *Design and Analysis of Experiments*, John Wiley & Sons, New York.
- Montgomery, D. C. (2003), *Diseño y análisis de experimentos*, Segunda Edición, Grupo Editorial Limusa, S.A., México.
- Myers, R. H. & Carter, W. H. (1973), 'Response Surface Techniques for Dual Response Systems', *Technometrics* **15**(2), 301–317.
- Myers, R. H. & Montgomery, D. C. (1995), *Response Surface Methodology: Process and Product Optimization Using Designed Experiments*, John Wiley & Sons, New York.

- Myers, R. H. & Montgomery, D. C. (1997), 'A tutorial on generalized linear models', *Journal of Quality Technology* **29**(3), 274–291.
- Myers, R. H., Montgomery, D. C., Vinning, G. G. & Robinson, T. J. (2010), *Generalized Linear Models: With Applications in Engineering and the Sciences*, John Wiley & Sons.
- Nelder, J. A. & Wedderburn, R. W. M. (1972), 'Generalized Linear Models', *Journal of the Royal Statistical Society, Series A* **135**(3), 370–384.
- Neter, J., Wasserman, W. & Kutner, M. H. (1990), *Applied Linear Statistical Models*, 3rd ed. Richard D. Irwin, Inc, Homewood, IL Boston, MA.
- Newman, D. (1939), 'The Distribution of Range in Samples from a Normal Population, Expressed in Terms of an Independent Estimate of Standard Deviation', *Biometrika* **31**(1/2), 20–30.
- Ostle, B. (1981), *Estadística aplicada*, Editorial Trillas, México.
- Pachón, A. J. (2003), Estudio de potencia para diferentes pruebas de normalidad T, Trabajo de grado, Universidad Nacional de Colombia, Bogotá.
- Pearson, E. S. & Hartley, H. (1954), *Biometrika Tables for Statisticians*, University Press, Cambridge.
- Pearson, E. S. & Hartley, H. O. (1996), 'Biométrika Tables for Statisticians', *Biométrika, Cambridge University-Press* **1**.
- Peterson, R. G. (1985), *Design and Analysis of Experiments*, Marcel Dekker inc, New York.
- R Development Core Team (2020), *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria, URL <http://www.R-project.org/>.
- Rao, C. R. (1973), *Linear Statistical Inference and Its Applications*, Second Edition, John Wiley & Sons, New York.
- Rao, C. R. & Mitra, S. (1971), *Generalized Inversa of Matrices and Its Applications*, John Wiley & Sons, New York.
- Ridout, M. S. (1990), *Non-convergence of Fisher's Method of Scoring - a simple example*, Vol. 20, GLIM Newsletter.
- Rosner, B. (2016), *Fundamentals of Biostatistics*, eighth edn, Cengage Learning, Boston.

- Roy, R. K. (1990), *A Primer on the Taguchi Method*, Van Nostrand Reinhold, New York.
- SAS (2020), *Statistical Analysis System-SAS User's*, guide sas institute edn.
- Satterthwaite, F. E. (1946), 'An Approximate Distribution of Estimates of Variance Components', *Biometrics* **2**(6), 110–114.
- Scheffé, H. (1953), 'A Method for Judging All Contrasts in the Analysis of Variance', *Biometrika* **40**(1/2), 87–104.
- Scheffé, H. (1959), *The Analysis of Variance*, John Wiley & Sons, New York.
- Searle, S. R. (1971), *Linear Models*, John Wiley & Sons, New York.
- Searle, S. R. (1987), *Linear Models for Unbalanced Data*, John Wiley & Sons, New York.
- Searle, S. R., Casella, G. & McCulloch, C. E. (1987), *Variance Components*, John Wiley & Sons, New York.
- Shapiro, S. S. & Wilk, M. B. (1965), 'An Analysis of Variance Test for Normality (complete samples)', *Biometrika* **52**(3/4), 591–611.
- Silveira Neto, S., Nakano, O., Bardin, D. & Villa Nova, N. A. (1976), *Manual de ecologia dos insetos*, Agronômica Ceres edn, Piracicaba.
- Siqueira, A. L. (1983), *Uso de transformação em análise de variância e análise de regressão*, Dissertação (mestrado em matemática e estatística), Universidade de São Paulo, São Paulo.
- Snedecor, G. W. & Cochran, W. G. (1967), *Statistical Method*, Iowa State University Press, Iowa.
- Sokal, R. R. & Rohlf, F. J. (1969), *Biometry, the Principles and Practice of Statistics in Biological Research*, W. H. Freeman and Company, San Francisco, California.
- Speed, F. M., Hocking, R. R. & Hackney, O. P. (1978), 'Methods of Analysis of Linear Models with Unbalanced Data', *Journal of American Statistical Association* **73**(361), 105–112.
- Steel, R. G. & Torrie, J. H. (1982), *Principles and Procedures of Statistics*, McGraw-Hill Book Co., New York.

- Taguchi, G. (1986), *Introduction to Quality Engineering*, American Supplier Inst., Dearborn.
- Taguchi, G. (1987), *Systems of Experimental Design: Engineering Methods to Optimize Quality and Minimize Cost*, UNIPUB/Kraus International Publications, New York.
- Tang, L. C. & Xu, K. (2002), 'A Unified Approach for Dual Response Surface Optimization', *Journal of Quality Technology* **34**(4), 437–447.
- Tang, P. C. (1938), 'The Power Function of the Analysis of Variance Tests with Tables and Illustrations of Their Use', *Statistical Research Memoirs* **2**, 126–149.
- Taylor, W. H. & Hilton, H. G. (1981), 'A Structura Diagram Symbolization for Analysis of Variance', *The American Statistician* **35**(2), 85–93.
- Tukey, J. W. (1949), 'One Degree of Freedom for Non-Aditivity', *Biometrics* **5**, 232–242.
- Tukey, J. W. (1953), *The Problem of Multiple Comparisons*, Unpublished Report, Pricenton University.
- Vining, G. (1998), 'A Compromise Approach to Multiresponse Optimization', *Journal of Quality Technology* **30**(4), 309–313.
- Vining, G. & Myers, R. (1990), 'Combining Taguchi and Response Surface Philosophies: A Dual Response Approach', *Journal of Quality Technology* **22**(1), 38–45.
- Wedderburn, R. W. M. (1974), 'Quasi Likelihood Functions, Generalized Linear Models and the Gauss-Newton Method', *Biometrika* **61**(3), 439–447.
- Wilcoxon, F. (1945), 'Individual Comparison by Ranking Methods', *Biometrics* **1**(6), 80–83.
- Wilcoxon, F. & Wilcoxon, R. A. (1964), *Some Rapid Approximate Statistical Procedures*, Lederle Laboratories.
- Wilk, M. B. & Kempthorne, O. (1957), 'Non-additivities in a latin square design', *Journal American Statistician Association* **52**(1), 218–236.
- Winer, B. J. (1991), *Statistical Principles in Experimental Design*, Mc Graw Hill, New York.

- Yates, F. (1934), Design and Analysis of Factorial Experiments, Technical Communication, Commonwealth Bureau of Soil Sciences, Harpenden, England.
- Yates, F. (1936), 'Incomplete Randomized Blocks', *Annals of Human Genetics* **7**, 121–140.
- Youden, W. J. (1964), 'Query 1: Inadmissible random assignments', *Technometrics* **6**(1), 103–105.
- Yuen, K. K. & Dixon, W. J. (1973), 'The Approximate Behaviour and Performance of the Two-sample Trimmed t', *Biometrika* **60**(2), 369–374.
- Zyskind, G. (1980), *Teoría de las hipótesis lineales*, Colegio de Postgraduados, Chapingo, México.

Índice

- Aditividad, 238
- Aleatorización, 14, 17–19, 22, 370
- Aleatorizados, 23
- Alias, 502, 504, 511, 517
- Ambiente experimental, 21
- Amplitud
 - estudentizada, 231
 - máxima, 230
- Análisis
 - canónico, 563, 566, 571
 - covarianza, 13, 14
 - de cordillera, 569, 570
 - de covarianza, 354, 369, 372
 - de datos, 30
 - de los residuales, 237
 - de regresión, 30
 - de residuos, 238
 - de varianza, 32, 35, 37, 80, 129, 508
 - estadístico, 30
 - gráfico, 239
- Análisis de varianza, 34
- Apuntamiento, 254
- Arreglos factoriales, 460
- Balanceado, 18
- Balanceados, 23
- Bloques, 14, 21, 311
 - ajustados, 316
 - aleatorios, 133
 - aleatorizados, 469
 - completamente aleatorizados, 141
 - completos, 403, 405
- Completos o Incompletos, 302
 - homogéneos, 279
 - incompleto, 305
 - incompletos, 23, 300, 301, 467, 469, 470, 478
 - incompletos balanceados, 311
- Coefficiente
 - de confianza, 229
 - de correlación, 61
 - de determinación, 548
 - de variación, 180, 241, 265
- Comparaciones
 - múltiples, 227
 - pareadas, 23, 61
- Componentes
 - de variación, 5
 - de varianza, 171, 173, 194, 202, 297
- Conducción del experimento, 30
- Confundidos, 33
- Confusión, 403, 461, 467
 - parcial, 468, 483, 486, 490
 - total, 468, 480, 483
- Congruencia, 460

Conjunto

de factores, 134

diseño, 134

Contraste, 163, 228, 420

Contrastes, 284

ortogonales, 407, 417, 422

Control

del error, 13, 25, 27, 32

en la aleatorización, 351

local, 17, 21

Convergencia en probabilidad, 49

Corrección por continuidad, 55

Correlación, 19

de los errores, 238, 242

de rangos, 247

intraclase, 174

Covariables, 3

Covarianza, 228

Cuadrado

Greco-Latino, 350

latino, 339, 350, 516

latinos, 353, 425

medios esperados, 300

Cuadro

latino, 157, 337

latino conjugado, 338

latino estándar, 338

latinos, 348

Curtosis, 51

Curvas características de

operación, 182, 190

Dato faltante, 293, 342

Datos faltantes, 291, 317

Decisión de gestión, 7

Dependencia lineal, 358

Desbalanceado, 18

Desvíos de supuestos, 237

Diagramas

de estructuras, 131, 199, 424

Diseño

Aleatorizado, 22

balanceados, 157

completamente aleatorizado,

37, 143, 155

completos, 23

de bloques, 157

de control del error, 29, 32

de experimento, 15

de experimentos, 6

de muestreo, 27

de observaciones, 32

de tratamientos, 25, 29

del experimento, 4

en bloques, 37

estadístico, 3

estándar, 23

experimental, 4, 24, 32, 43

factorial, 490

factorial 2^k , 419

factoriales, 436, 444, 489

factoriales fraccionados, 501

incompletos, 23

ortogonal, 556

Distribución

asintótica, 177, 245

binomial, 417

condicional, 61

discretas, 251

exponencial, 51

normal, 49, 417

normal multivariada, 31

t, 48

Dos muestras aleatorias, 43

Ecuaciones

normales, 83

normales reducidas, 94

Efecto

Admisibles, 135

- aleatorios, 157
- cuadrático, 430
- de curvatura, 423
- de interacción, 414
- de los tratamientos, 17
- de tratamiento, 7, 19, 33
- de tratamientos, 22
- fijo, 33
- fijos, 29, 157
- lineales, 423
- mixtos, 133
- principales, 402, 412
- Eficiencia, 292, 343
 - relativa, 373, 471, 524
- Error, 19, 22
 - experimental, 15
 - de muestreo, 35, 293
 - de tipo II, 182
 - estándar, 18, 311
 - experimental, 10, 12, 16, 17, 19, 20, 22, 25, 27, 35, 301
 - interbloque, 468, 472
 - intrablock, 302, 318, 468
 - muestral, 18
 - observacional, 27
 - puro, 553
 - sistemáticos, 22
 - tipo I, 19, 180, 251
 - tipo II, 180, 183, 191
- Esperanzas de los cuadrados
 - medios, 33
- Estadística
 - de la trimedia, 57
 - de Wilcoxon, 52
 - pivotal, 44
- Estadístico
 - de prueba, 44, 46
- Estimabilidad, 84, 160
- Estimación de datos faltantes, 317
- Estimador
 - de Hodges-Lehmann, 55
 - insesgado, 13
- Estimadores lineales insesgados, 85
- Estructura
 - del control del error, 29
 - factorial, 25
- Estructuras factoriales
 - asimétricas, 25
 - simétricas, 25
- Experimentación
 - secuencial, 542
- Experimento, 4, 401
 - absoluto, 5
 - comparativo, 6
 - comparativos, 8
 - factorial, 435
 - factorial fraccionado, 27
 - factoriales, 518
 - planeados, 7
- Factor
 - de clasificación, 30
 - de corrección, 55
 - de eficiencia, 312
- Factores, 9, 11, 28, 29
 - aleatorios, 198
 - de bloqueo, 25
 - de clasificación, 14
 - extraños, 20
 - inertes, 134
 - vivos, 134
- Factorial
 - fraccionado, 505, 510
- Factoriales
 - asimétricos, 489
 - fraccionados, 403, 501, 515, 516
- Falta

de ajuste, 552–555
 Fisher, 179, 279, 311
 Forma canónica del modelo, 564
 Frecuencias relativas, 53
 Fuente de variación, 21
 Fuentes
 de variación, 10, 16, 19
 extrañas de variación, 12
 Funciones
 estimables, 31, 102
 estimables tipo I, 103
 estimables tipo II, 104
 estimables tipo III, 105
 estimables tipo IV, 107
 Función
 de distribución acumulada,
 56
 Generador, 503
 Genotipo, 175
 Grado de confiabilidad, 28
 Grados de libertad, 14, 20
 Gráfico
 de probabilidad normal, 240
 de residuos, 240
 Gráficos de perfiles, 238
 Heterocedasticidad, 238
 Heterogeneidad de varianza, 416
 Hipercuadrado, 353
 Hipótesis, 4
 lineal general, 164, 169
 nula, 54, 291
 Homocedasticidad de los errores,
 238
 Homogeneidad de varianza, 250,
 260
 Independencia, 19
 Inferencia, 31
 asintótica, 50

Información
 complementaria, 195
 intrabloque, 312
 Interacciones, 402
 generalizadas, 478, 483
 Interacción, 135
 Intervalo de confianza, 48, 56
 Intervalos
 de confianza, 44, 46
 Inversa generalizada, 30
 Irrestritos, 23
 Kruskal-Wallis, 176
 Localidades, 297
 Mann-Whitney, 178
 Material
 experimental, 8, 16, 22, 25,
 28, 311
 Matriz
 de concordancia, 302
 de covarianzas, 58
 de incidencia, 302
 de proyección, 308, 546
 inversa de covarianzas, 60
 ortogonal, 568
 Media
 aritmética, 244
 condicional, 54
 Mediana, 55, 56
 Medias
 ajustadas, 369
 cuadráticas, 175
 de celda, 165
 no ajustadas, 369
 MELI, 164, 283, 367
 Modelamiento estadístico, 31
 Modelo
 de efectos aleatorios, 5, 8
 de efectos fijos, 6, 8

- de efectos mixtos, 8
- de medias de celdas, 82
- de regresión, 543
- estadístico, 31
- lineal, 17, 29, 32, 194, 237, 423
- lineal aditivo, 158
- lineales generalizados, 250
- lineales particionados, 93
- mixto, 157
- particionado en dos partes, 93
- particionado en k partes, 98
- particionado en tres partes, 97
- superparametrizado, 79, 90, 159
- Muestra combinada, 54
- Muestras
 - independientes, 43, 47
 - pareadas, 62
- Muestreo y diseño de
 - observaciones, 29
- Multiplicadores de Lagrange, 200, 201, 557, 570
- Máxima verosimilitud, 30, 243
- Máximo, 543
 - ascenso, 555, 556, 559
 - verosimilitud, 544
- Método
 - científico, 3
 - de Bonferroni, 234
 - de Bonferroni (Fisher), 229
 - de Duncan, 232
 - de la trayectoria, 555
 - de Tukey, 231, 235
- Métodos
 - técnicos, 13
- Mínimo, 543
- Mínimos cuadrados, 30, 243, 246, 371, 544
- Nivel de significación, 53, 54, 59
- Niveles, 5, 10, 28
- No aditividad, 243, 255
- No estimabilidad, 358
- No homocedasticidad, 259
- No normalidad, 259, 263
- Normales multivariadas, 59
- Número de réplicas, 185, 187, 190
- Observaciones
 - atípicas, 238
 - empatadas, 53
- Observación faltante, 289
- Paquete estadístico, 31
- Parcela faltante, 291
- Parcelas
 - divididas, 501, 518
- Parcialmente balanceados, 23
- Parámetro
 - de localización, 57
 - de no centralidad, 183, 196
 - de sesgo, 52
- Parámetros, 80
- Plan experimental, 29
- Planes experimentales, 29
- Poblaciones normales
 - multivariadas, 58
- Población objetivo, 11
- Polinomio
 - de segundo grado, 542
- Potencia, 182, 185
- Precisión del experimento, 18
- Predicción, 4
- Primer
 - orden, 540
 - orden con interacción, 541

Probabilidad acumulada, 239

Procedimiento

MIXED, 148

NPAR1WAY, 179

RANK, 179

VARCOM, 148

Prueba

de equivalencia, 549

de hipótesis, 31, 35

de Mann-Whitney, 52

de no aditividad, 255

de normalidad, 250

de Pitman, 61

de rangos, 63

de razón de verosimilitud,
44, 47

del rango de Wilcoxon, 52
parcial F , 549

Punto

de silla, 562, 571

estacionario, 561, 563, 566,
569

Rangos estudentizados, 188

Razón de verosimilitud, 246, 248

Re-aleatorizar, 20

Región

de confianza, 55, 230

óptima, 569

Regresión lineal, 363

Relación de definición, 503, 510,
511, 515

Replicaciones, 14, 16, 18

Replicación, 22

fraccionada, 467

Resolución, 505

Restricciones múltiples, 23

Restricción, 44

única, 23

Réplicas, 20

Segundo

orden, 542

Series

de cuadrados latinos, 345

de Taylor, 261

Sesgo, 51

Simetría, 254

Sistema consistente, 305

Sistemático, 23

Subgrupo intrabloque, 477

Submuestreo, 27, 194, 196, 198,
293, 297

Suma

de cuadrados, 93, 102, 359,
415

de cuadrados ajustados, 309

de cuadrados del residuo en
la regresión, 62

de cuadrados tipo I, 103

Superficie

de respuesta, 542

Superficies

de respuesta, 539

Tamaño

de muestra, 28, 191

óptimo, 200

Teoría

de grupos, 426, 438, 461,
481

estadística, 6

Transformaciones, 260

lineales, 90

Transformación de Box-Cox, 265

Tratamiento, 5, 9–12, 16, 17, 19,
21, 25, 29, 36

ajustados, 304

comunes, 301

control, 191, 233

testigo o control, 12

Trimedia, 56

Unidad

- experimental, 8, 9, 13, 18, 30, 33
- muestral, 8
- observacional, 33

Unidades

- experimentales, 13, 17, 19, 21, 24, 29
- observacionales, 27

Uso de transformaciones, 250

Valor crítico, 55

Variabilidad total, 174

Variable

- concomitante, 356
- dependiente, 28
- respuesta, 6, 28, 38

Variables

- aleatorias, 58
- canónicas, 564
- codificadas, 540

concomitantes, 14, 354

cuantitativas, 14

explicativas, 3

independientes, 28, 43

naturales, 540

no controlables, 3

potenciales, 13

respuesta, 3, 28

respuestas, 9

Variación

- dentro de bloques, 279
- entre bloques, 279

Varianza

- asintótica, 50
- del error, 18
- muestral conjunta, 57, 58
- máxima, 229

Vector

- de parámetros, 30
- de tratamientos, 32
- de variables, 79

Índice de heredabilidad, 174

Editado por el Centro Editorial de la Facultad de Ciencias,
Universidad Nacional de Colombia, sede Bogotá.
Fuente principal Baskerville y Fira Sans.

Este libro desarrolla temas de interés para aquellos que dentro de sus investigaciones utilizan métodos experimentales. En los cinco primeros capítulos, se exploran diferentes conceptos del diseño experimental, se revisa la comparación de dos muestras aleatorias procedentes de poblaciones con distribución conocida o no, se detallan modelos lineales de rango incompleto y se presentan diagramas de estructuras para modelos balanceados de efectos mixtos y el diseño completamente aleatorizado.

En los capítulos seis al doce, se revisan los métodos de comparaciones planeadas y no planeadas, se exploran diseños en bloques completamente aleatorizados y diseños de cuadros latinos y grecolatinos, se examina el análisis de covarianza, se aborda el estudio de los diseños experimentales con arreglos factoriales, se estudian los diseños factoriales fraccionados y los diseños en parcelas divididas y subdivididas y se lleva a cabo una introducción a la metodología de superficies de respuesta. Finalmente, en el capítulo trece, se hace una introducción a los diseños experimentales con respuesta dentro de la familia exponencial.

