

FRANCISCO MONTES SUAY

ESTADÍSTICA MULTIVARIANTE (EXPLICADA)

UNIVERSITAT DE VALÈNCIA

Índice general

1 Álgebra matricial	5
2 Muestras de una normal multivariante	15
3 Coeficientes de correlación muestrales	45
4 El estadístico T^2 generalizado	71
5 Clasificación de observaciones	89
6 La distribución de la matriz de covarianzas muestral y de la varianza muestral generalizada	109

Capítulo 1

Álgebra matricial

Se pretende en este primer capítulo recordar algunos conceptos referentes al cálculo matricial y materias con él relacionadas, por ser éste útil matemático de gran importancia para facilitar los cálculos que el manejo de matrices multivariantes implican.

Enérgicamente resultaría poco insistir en algunos conceptos de nostra memoria, a saber, definiciones referente a los distintos tipos de matrices, operaciones elementales con rectas y matrices, como suma, producto, producto por un escalar, etc. así como la correspondencia biunívoca existente entre las matrices y los sistemas lineales, el producto interior matricial, la transposición de matrices, la definición y obtención del determinante de una matriz cuadrada, etc.

Despedimos ahora se otros conceptos, nítidos de algunos de ellos bien visto detallaremos propiedades de estos.

1. INVERSA DE UNA MATRIZ

Solo existe en para las matrices cuadradas ~~trio~~ no singulares. Es definida por $A \cdot A^{-1} = A^{-1} \cdot A = I$.

Se comprueba que su existencia está ligada al valor del determinante de A , por cuanto si este es 0, aquella no existe. Propiedades de inversas.

- La inversa de una matriz simétrica también lo es.
- La inversa de la traspuesta es la traspuesta de la inversa.
- La inversa del producto verifica

$$(ABC)^{-1} = C^{-1} \cdot B^{-1} \cdot A^{-1}$$

- La inversa de una matriz diagonal es una matriz diagonal cuyos elementos son los inversos de los elementos propios.

2. RANGO DE UNA MATRIZ

Sea A una matriz $k \times p$, con $k \leq p$. El rango de A es el número de rectas filas ligeramente independientes en la matriz. Si $p \leq k$, la definición es análoga constituyendo filas por columnas. Se demuestra que en cualquier caso el rango de una matriz es único, independientemente de su criterio considerando las rectas filas o columnas.

Atendiendo al valor del determinante de los menores complementarios en una matriz A , podemos afirmar que:

la matriz A de rango r no contiene al menos un menor ~~de~~ $r \times r$ distinto de cero, siendo todos los demás con dimensiones mayor que r .

Algunas propiedades de inversas:

- El rango de A' y el de A son iguales.
- El rango de $A' \cdot A$ es igual al de A e igual al de $A \cdot A'$.
- El rango de A no altera si se pre o post-multiplica A por una matriz no singular.

Como consecuencia de c) podemos afirmar que el rango de una matriz A no cambia si

- Se intercambian dos filas (columnas) cualesquiera
- Multiplicando cada fila (columna) por un escalar
- Añadiendo a una fila (columna) los elementos de otra previamente multiplicados por un escalar.

y todo ello por que las operaciones dadas en estas tres propiedades pueden llevarse a cabo mediante premultiplicación (caso de filas) o postmultiplicación (caso de columnas) de la matriz A por una matriz no singular.

$$A = \begin{bmatrix} 5 & 1 \\ -2 & 3 \\ 3 & 2 \end{bmatrix} \quad E = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad EA = \begin{bmatrix} -2 & 3 \\ 5 & 1 \\ 3 & 2 \end{bmatrix}$$

Operando sobre las filas y columnas nos permiten transformar una matriz A , de rango r , en su correspondiente canónica F , que tiene la forma

$$F = \begin{bmatrix} 1 & 0 & \cdots & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & 1 & \cdots & 0 \\ 0 & 0 & \cdots & 0 & \cdots & 0 \end{bmatrix}$$

es decir, las r primeras posiciones de la diagonal principal tienen en el uno. Si designamos por $R_1 - R_p$ y $C_2 - C_q$ estos cambios de filas y columnas podemos escribir

$$R_p - R_1 \ A \ C_2 - C_q = P A Q = F$$

Si A es cuadrada y de rango n (completo), entonces

$$R_q - R_1 \ A = I$$

y de aquí

$$A^{-1} = R_p - R_1 I$$

Este hecho se aprovecha para invertir matrices de forma rápida y sencilla, útil en los cálculos de derivadas de matrices.

3. INVERSA GENERALIZADA

La definición dada anteriormente es sólo aplicable a matrices cuadradas no singulares. Se trata de introducir un concepto de inversa que generealice el anterior.

La G -inversa de una matriz A de cualquier dimensión viene dada por:

$$(1) \ A G A = A$$

Si la dimensión de A es $p \times q$ y su rango r , la dimensión de G es $q \times p$ y su rango es r .

Existen otras definiciones, por ejemplo la dada a Penrose que exige además

$$G A G = G \quad (GA)^T = GA \quad (AG)^T = AG$$

la obtención de la G definida en (1) puede hacerse a partir de la reducción canónica de A , como sigue:

$$P A Q = F = \begin{bmatrix} D & 0 \\ 0 & 0 \end{bmatrix}$$

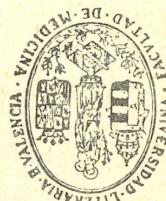
donde D es una matriz diagonal $r \times r$ (no necesariamente I) y el resto matrices nulas de dimensión adicional.

P y Q las anteriormente definidas a partir de operaciones en filas y columnas. Definiremos ahora

$$F^- = \begin{bmatrix} D^{-1} & 0 \\ 0 & 0 \end{bmatrix}$$

entonces $G = Q F^- P$, es una inversa generalizada de A , que desde luego no es única. Si A es cuadrada y no singular, entonces $G = A^{-1}$ y es única.

EXAMENES



4. SISTEMAS DE ECUACIONES LINEALES

Recordemos que un sistema de la forma

$$a_{11}x_1 + \dots + a_{1n}x_n = c_1$$

$$a_{m1}x_1 + \dots + a_{mn}x_n = c_m$$

admitir una representación matricial mediante

$$Ax = c$$

con

$$A = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix} \quad x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \quad c = \begin{bmatrix} c_1 \\ \vdots \\ c_m \end{bmatrix} \quad \text{si } c = [0], \text{ el sistema se llama homogéneo}$$

(1) El sistema para una solución no nula ni la matriz ampliada $[A|c]$ de dimensión $m \times (n+1)$ tiene el mismo rango que la matriz A . (Se dice entonces que el sistema es consistente)

Estudiaremos los tipos de sistemas y sus soluciones en función del rango de A y $[A|c]$.

a) Sistemas no homogéneos: A cuadrada y no singular

La solución es única y viene dada por

$$x = A^{-1}c$$

b) Sistemas no homogéneos: $A \in \mathbb{R}^{m \times n}$ y de rango r

Si se satisface (1) existe una solución que puede obtenerse hallando r ecuaciones linealmente independientes, resolviendo para r incógnitas en función de las constantes y de las restantes $n-r$ indómitas.

c) Sistemas homogéneos

Obviamente el rango de $[A|0]$ es siempre el mismo que el de (A) por tanto siempre tienen solución.

c.1) Si $\text{rango}(A) = n$ = número de incógnitas, solución única dada por $x = [0]$

c.2) En cualquier otro caso solución del tipo expresada en b).

En cualquier caso la solución puede expresarse en función de la inversa generalizada mediante la siguiente expresión sabida a Rao (1962), siendo el sistema consistente.

$$x^* = Gc + (GA - I)z$$

dónde z es un vector $n \times 1$ de constantes arbitrarias, observe que si existe A^{-1} , entonces $x^* = A^{-1}c$, como ya habíamos

5. MATRICES ORTOGONALES

Un vector se dice que es ortogonal respecto de otro si su producto interior es nulo.

Una matriz T se dice ortogonal si su inversa es igual a su transpuesta, es decir $T^{-1} = T^T$, siendo T cuadrada. Más concretamente se exige que los vectores sean unitarios, es decir de norma unidad. De esta definición se deduce que:

$$TT^T = T^T T = I$$

Algunas propiedades de interés:

- Las columnas de una matriz orthogonal son ortogonales.
- El determinante de una matriz orthogonal es siempre $1 \text{ o } -1$.

En efecto $|TT'| = |I| = 1$ y $|T| = |T'| = \pm 1$

- El producto de matrices ortogonales de la misma dimensión es también una matriz orthogonal.

J. FORMAS CUADRATICAS

Una forma cuadrática en las variables x_1, \dots, x_n es una expresión del tipo

$$f(x_1, \dots, x_n) = a_{11}x_1^2 + \dots + a_{nn}x_n^2 + 2a_{12}x_1x_2 + \dots + 2a_{1n}x_1x_n + \dots + 2a_{n-1,n}x_{n-1}x_n = \\ = \sum \sum a_{ij}x_i x_j \quad \text{con } a_{ij} = a_{ji} \quad \text{pudiendo ser cero algún } a_{ij}$$

De inmediato se observa que una forma cuadrática admite notación matricial, como sigue:

$$f(x_1, \dots, x_n) = x^T A x$$

Donde A es una matriz simétrica $n \times n$. Las formas cuadráticas juegan un importante papel en la estadística, tanto univariante como multivariante. Por ejemplo, la suma de los cuadrados de los desviaciones respecto de la media muestral

$$\sum_{i=1}^N (x_i - \bar{x})^2 = \sum_{i=1}^N x_i^2 - \frac{1}{N} \left(\sum x_i \right)^2$$

es una forma cuadrática cuya matriz de coeficientes viene dada por:

$$A = \begin{bmatrix} \frac{N-1}{N} & -\frac{1}{N} & \dots & -\frac{1}{N} \\ -\frac{1}{N} & \frac{N-1}{N} & \dots & -\frac{1}{N} \\ \vdots & \vdots & \ddots & \vdots \\ -\frac{1}{N} & -\frac{1}{N} & \dots & \frac{N-1}{N} \end{bmatrix}$$

Carácter de una forma cuadrática

- Definida positiva, semidefinida positiva.

Una matriz simétrica A y su forma cuadrática asociada se dice que es definida positiva si

$$x^T A x > 0, \forall x \neq 0.$$

Si $x^T A x \geq 0, \forall x \neq 0$ entonces se la denomina semidefinida positiva.

- Definida negativa, semidefinida negativa.

Id con los signos cambiados.

- Indefinida

Si puede tomar cualquier valor positivo, negativo o nulo.

Algunas propiedades de las formas cuadráticas definidas y semidefinidas positivas

- Las formas cuadráticas definidas positivas tienen matriz de campo completo. Es posible mediante complementación de matrices menores reducir dichas formas a expresiones del tipo

$$d_1 y_1^2 + \dots + d_n y_n^2 \quad d_i > 0, f_i$$

EXAMENES



Algo similar ocurre con las semidefinidas positivas, pero ahora la expresión es

1 (3)

$$d_1 y_1^2 + \dots + d_r y_r^2 \quad \text{dijo} \quad r \leq n \quad \text{el rango de la forma cuadrática matriz.}$$

2) No obstante para determinar el carácter de una forma basta a dar ahora una condición necesaria y suficiente. Tomaremos en primer lugar la cuestión de los determinantes de los menores principales, a saber:

$$p_0 = 1 \quad p_1 = a_{11} \quad p_2 = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} \quad \dots \quad p_i = \begin{vmatrix} a_{11} & \dots & a_{1i} \\ a_{21} & \dots & a_{2i} \\ \vdots & \ddots & \vdots \\ a_{ii-1} & \dots & a_{ii} \end{vmatrix} \quad \dots \quad p_n = |A|$$

Si el rango de A es r , se dice que A es regular si $p_r \neq 0$ y no hay dos p_i consecutivos en la matriz iguales a cero. Siempre es posible, intercambiando filas y columnas, chocar una matriz simétrica en una forma regular. Entonces, si A es una matriz definida regularmente, tenemos:

2.a) Una condición suficiente para la definición positiva es que $p_i > 0$, $i=1, \dots, n$

2.b) Id. para la semi definición positiva es que $p_1 > 0, \dots, p_r > 0$ y los restantes $n-r$ p_i sean negativos, donde $r \leq n$.

Se puede demostrar aplicando esto que la forma cuadrática de la suma de los menores de los diagonales respectos de la media es semi definida positiva con rango $N-1$ para su matriz. Los distintos p_i tienen un valor

$$p_i = \frac{1}{N} (N-1)(i-1).$$

6. RAÍCES Y VECTORES CARACTERÍSTICOS DE UNA MATRIZ

Las raíces características de una matriz A , $p \times p$, son los valores de la ecuación determinante

$$|A - \lambda I| = 0$$

El determinante es un polinomio de grado p en λ que tiene por tanto p raíces. Aplicando el desarrollo de Laplace del determinante característico, podemos escribir

$$|A - \lambda I| = (-\lambda)^p + s_1 (-\lambda)^{p-1} + \dots + s_{p-1} (-\lambda) + |A|$$

donde s_i es ~~la~~ la suma de todos los determinantes de los menores principales de dimensión $i \times i$. Si mira en particular la suma de los elementos de la diagonal principal de A , o sea $\text{tr}(A)$. De la teoría se las obtiene de una ecuación polinomial, tenemos de inmediato que:

1) El producto de las raíces características de A es igual a $|A|$

2) La suma de las raíces características de A es igual a $\text{tr}(A)$

Algunas propiedades de matrices y de posterior uso de las raíces características son:

a) las raíces características de una matriz simétrica con elementos reales son todas reales.

b) las raíces características de una matriz definida positiva son todas positivas.

c) Para una matriz $n \times n$ semi definida positiva de rango $r \leq n$, hay exactamente r raíces características positivas y $n-r$ negativas.

d) las raíces características no nulas del producto AB son iguales a las raíces no nulas de BA . Por tanto $\text{tr}(AB) = \text{tr}(BA)$

e) las raíces características de una matriz diagonal son los elementos de la diagonal.

A cada raíz característica podemos asociar un vector característico, cuyos elementos satisfacen la ecuación homogénea

$$[A - \lambda_i I] x_i = 0$$

como el determinante $|A - \lambda_i I| = 0$ existe siempre una solución no trivial para x_i que quedará determinado a excepción de un factor de escala. Dada la importancia de los vectores y raíces características, obtenidas a partir de matrices simétricas, daremos a continuación algunas propiedades interesantes.

- a) Si $\lambda_i \neq \lambda_j$ son raíces características de una matriz simétrica A , entonces x_i y x_j , los vectores asociados son ortogonales. En efecto:

$$Ax_i = \lambda_i x_i \quad Ax_j = \lambda_j x_j$$

premultipliando por x_j^T y x_i^T respectivamente

$$x_j^T A x_i = \lambda_i x_j^T x_i \quad y \quad x_i^T A x_j = \lambda_j x_i^T x_j$$

y dada la simetría de A , tenemos

$$\lambda_i x_j^T x_i = \lambda_j x_i^T x_j$$

y teniendo $\lambda_i \neq \lambda_j$ esto implica que $x_j^T x_i = 0$.

- b) Para cualquier matriz simétrica real A existe una matriz orthogonal P tal que

$$P^T A P = D$$

donde D es una matriz diagonal cuyos elementos son las raíces características de A . Las columnas de P ^{son} los vectores característicos normalizados de A

Estas propiedades para las matrices simétricas tienen una aplicación inmediata en las formas cuadráticas. En efecto, si aplicamos ~~esta~~ la transformación orthogonal P a

$$x = Py$$

a las variables de la forma cuadrática $x^T A x$, tendremos:

$$x^T A x = y^T P^T A P y = y^T D y = \lambda_1 y_1^2 + \dots + \lambda_r y_r^2$$

7. MATRICES PARTICIONADAS

Se trata de presentar una matriz ~~esta~~ formada por las submatrices que la componen y que vienen determinadas por agrupaciones de determinadas filas y columnas siguiendo criterios de homogeneidad, etc. Puede entonces una matriz aparecer como

$$A = \begin{bmatrix} A_{11} & \cdots & A_{1n} \\ \vdots & \ddots & \vdots \\ A_{m1} & \cdots & A_{mn} \end{bmatrix}$$

donde A_{ij} contiene r_i filas y c_j columnas y donde todas las submatrices de una misma fila tienen el mismo número de filas y todas las de una misma columna el mismo número de columnas. Con estas matrices pueden llevarse a cabo las mismas operaciones que en el caso no agrupado, teniendo en cuenta, en todo caso, la naturaleza no escalar de los elementos. Así, por ejemplo, si A y B tienen submatrices de igual dimensión podemos dividir

$$A+B = \begin{bmatrix} A_{11}+B_{11} & \cdots & A_{1n}+B_{1n} \\ \vdots & \ddots & \vdots \\ A_{m1}+B_{m1} & \cdots & A_{mn}+B_{mn} \end{bmatrix} \quad o \text{ bien}$$

$$AB = \begin{bmatrix} \sum_{i=1}^n A_{1i} B_{i1} & \cdots & \sum_{i=1}^n A_{1i} B_{ip} \\ \hline \vdots & \ddots & \vdots \\ \sum_{i=1}^n A_{mi} B_{i1} & \cdots & \sum_{i=1}^n A_{mi} B_{ip} \end{bmatrix}$$

Existen expresiones para la matriz inversa de una matriz particularizada en función de la adyacente que la componen,¹ así como para el determinante (uso de la traza) de una matriz cuadrada no singular. Por ejemplo, para una matriz de la forma

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \quad \text{con } A_{11}, A_{22} \text{ cuadradas y no singulares dada su naturaleza de matriz principal}$$

$$A^{-1} = \begin{bmatrix} (A_{11} - A_{12} A_{22}^{-1} A_{21})^{-1} & -(A_{11} - A_{12} A_{22}^{-1} A_{21})^{-1} A_{12} A_{22}^{-1} \\ -A_{22}^{-1} A_{21} (A_{11} - A_{12} A_{22}^{-1} A_{21})^{-1} & A_{22}^{-1} + A_{22}^{-1} A_{21} (A_{11} - A_{12} A_{22}^{-1} A_{21})^{-1} A_{12} A_{22}^{-1} \end{bmatrix}$$

para el determinante

$$|A| = |A_{11}| \cdot |A_{22} - A_{12} A_{11}^{-1} A_{21}|. \quad \text{si } A_{11} \text{ es no singular, o bien}$$

$$|A| = |A_{22}| \cdot |A_{11} - A_{12} A_{22}^{-1} A_{21}| \quad \text{si } A_{22} \text{ es no singular.}$$

8. DIFERENCIACIÓN CON VECTORES Y MATRICES.

Sea $f(x)$ una función continua de los elementos del vector $x^t = [x_1, \dots, x_p]$ cuyas primeras y segundas derivadas parciales existen para todos los puntos x de una determinada región del espacio euclídeo p -dimensional. El vector operador derivada parcial lo definimos como

$$\frac{\partial}{\partial x} = \begin{bmatrix} \frac{\partial}{\partial x_1} \\ \vdots \\ \frac{\partial}{\partial x_p} \end{bmatrix}$$

aplicando a $f(x)$ una vez a $\frac{\partial f(x)}{\partial x}^t = \left[\frac{\partial f(x)}{\partial x_1} \quad \dots \quad \frac{\partial f(x)}{\partial x_p} \right]^t$.

Algunos casos de funciones y sus derivadas especialmente importantes son:

1) La función constante

$$2) \quad f(x) = a^t x \quad , \quad \frac{\partial f(x)}{\partial x}^t = a^t$$

$$3) \quad f(x) = x^t A x \quad \text{una forma cuadrática. Escribamos la forma de la manera siguiente:}$$

$$x^t A x = \sum_{i,j} \{ a_{ij} x_i x_j \} = a_{ii} x_i^2 + 2 x_i \sum_{j \neq i} a_{ij} x_j + \sum_{i \neq j} a_{ij} x_i x_j$$

derivando parcialmente respecto de x_i

$$\frac{\partial f(x)}{\partial x_i} = 2 a_{ii} x_i + 2 \sum_{j \neq i} a_{ij} x_j = 2 \sum_{j=1}^p a_{ij} x_j = 2 a_i^t x$$

si por a_i^t designamos la i -ésima fila de la matriz simétrica A . Entonces el vector de las derivadas parciales rendería dado por

$$\frac{\partial f(x)}{\partial x} = 2 A x$$

4) Si se trata de una función cuadrática más general $h(x) = (a - Cx)^t K (a - Cx)$ con K simétrica $N \times N$, $C = [C_1, \dots, C_p]$ matriz de constantes $N \times p$, a un vector $N \times 1$.

Haciendo $u = a - Cx$, las derivadas de $h(x)$ pueden calcularse aplicando la regla de la cadena:

$$\frac{\partial h(x)}{\partial x_i} = \sum_{j=1}^N \frac{\partial(u^T u)}{\partial u_j} \cdot \frac{\partial u_j}{\partial x_i} = -2 \sum_{j=1}^N k_j u \cdot e_j = -2 u^T K C_i \quad i=1, \dots, p$$

y de aquí

$$\frac{\partial h(x)}{\partial x} = -2 C' K (a - Cx).$$

- 5) La matriz de las derivadas de segundo orden (parciales) se la denomina Hessiano. En el caso de la forma cuadrática $f(x) = x^T A x$ dicha matriz es $2A$. El Hessiano es necesariamente simétrico si nuestras condiciones originales de continuidad y existencia de las derivadas parciales de primer y segundo orden son satisfechas por $f(x)$.

Determinación de máximos y mínimos

Ya conocemos las condiciones necesarias para la existencia de máximos o mínimos. Es muy interesante para nosotros las aplicaciones. Si queremos obtener los extremos estacionarios de $h(x)$ del apartado 4) anterior, tendremos que el vector x_* donde se encuentre el extremo debe satisfacer:

$$C' K C x_* = C' K a$$

y si $C' K C$ es de rango completo p, tendremos una solución única dada por $x_* = (C' K C)^{-1} C' K a$. Si K es definida positiva y C tiene rango p, el Hessiano $2C' K C$ es definitivo positivo y obtendremos un mínimo.

Máximos y mínimos utilizando λ

Si utilizamos el método de multiplicación de la grange. Escribiríamos en lo siguiente

$$h(x, \lambda) = f(x) - \lambda [g(x) - c]$$

donde $f(x)$ es la función a maximizar o minimizar y $g(x) = c$ es la restricción. Para un valor estacionario obtenido tendremos

$$\frac{\partial h(x, \lambda)}{\partial x} = \frac{\partial f(x)}{\partial x} - \lambda \frac{\partial g(x)}{\partial x} = 0$$

$$\frac{\partial h(x, \lambda)}{\partial \lambda} = -g(x) + c = 0$$

en la práctica se obtiene x después de haber eliminado λ en el sistema de ecuaciones.

Veamos un ejemplo para el caso de una forma cuadrática $f(x) = x^T A x$, con A definida positiva, sujeta a la restricción $x^T x = 1$. Entonces

$$h(x, \lambda) = x^T A x - \lambda (x^T x - 1)$$

entonces

$$\frac{\partial h(x, \lambda)}{\partial x} = 2Ax - 2\lambda x = 0 \rightarrow [A - \lambda I]x = 0$$

que es la ecuación característica de A . Premultiplicando por x^T y haciendo de la restricción tenemos

$$x^T [A - \lambda I]x = 0 \rightarrow x^T A x - \lambda = 0 \rightarrow \lambda = x^T A x$$

entonces si $f(x)$ debe ser un máximo, λ deberá ser la mayor de todas las raíces características, y x el vector característico asociado. La restricción da de qué modo vector debe tener módulo 1. Análogamente para el mínimo de $f(x)$.

Derivada de una matriz y de su determinante

La derivada del determinante de A respecto de un elemento A_{ij} podemos encontrarla a partir del desarrollo de $|A|$ en factores de la i fila y la j columna. De hecho:

$$\frac{\partial |A|}{\partial a_{ij}} = \sum_{k=1}^n (a_{ik}A_{1k} + \dots + a_{ik}A_{jk} + \dots + a_{ik}A_{nk}) = A_{ij}$$

Para derivar una matriz respecto de los elementos que la constituyen tendremos. Sea \mathbf{X} una matriz $m \times n$ con elementos generico x_{ij} , la derivada respecto a este elemento sera

$$\frac{\partial \mathbf{X}}{\partial x_{ij}} = J_{ij}$$

donde J_{ij} es una matriz $m \times n$ con un 1 en la posición i,j -ésima y ceros en resto. Si \mathbf{X} es simétrica

$$\frac{\partial \mathbf{X}}{\partial x_{ij}} = J_{ij} + J_{ji} \quad i \neq j$$

La regla para derivar un producto de matrices es similar a la utilizada para escalar. Supongamos entonces que \mathbf{X} y \mathbf{Y} son dos matrices conformes y que ambas son funciones continuas de t a través de $x_{ij}(t)$ e $y_{ij}(t)$. Entonces

$$\frac{\partial \mathbf{XY}}{\partial t} = \frac{\partial \mathbf{X}}{\partial t} \mathbf{Y} + \mathbf{X} \frac{\partial \mathbf{Y}}{\partial t}$$

Esta fórmula nos va a permitir obtener la derivada de la inversa de una matriz cuadrada no singular.

Veamos

$$\mathbf{I} = \mathbf{XX}^{-1}$$

$$\frac{\partial \mathbf{I}}{\partial x_{ij}} = \frac{\partial \mathbf{X}}{\partial x_{ij}} \cdot \mathbf{X}^{-1} + \mathbf{X} \cdot \frac{\partial \mathbf{X}^{-1}}{\partial x_{ij}} = 0$$

$$J_{ij} \mathbf{X}^{-1} + \mathbf{X} \frac{\partial \mathbf{X}^{-1}}{\partial x_{ij}} = 0 \rightarrow \frac{\partial \mathbf{X}^{-1}}{\partial x_{ij}} = - \mathbf{X}^{-1} J_{ij} \mathbf{X}^{-1}$$

Si \mathbf{X} es simétrica

$$\frac{\partial \mathbf{X}^{-1}}{\partial x_{ij}} = \begin{cases} -\mathbf{X}^{-1} J_{ii} \mathbf{X}^{-1} & i=j \\ -\mathbf{X}^{-1} (J_{ij} + J_{ji}) \mathbf{X}^{-1} & i \neq j \end{cases}$$

Capítulo 2

Muestras de una normal multivariante

1. VARIABLES ALEATORIAS MULTIDIMENSIONALES

Un vector aleatorio multidimensional \mathbf{X} , es un vector del tipo

$$\mathbf{x}^1 = [x_1, \dots, x_p]$$

cuyos elementos son variables continuas cuyas densidades vienen dadas por $f_i(x_i)$, y cuyas funciones de distribución son $F_i(x_i)$, $i=1, \dots, p$. Recordemos que la función de distribución conjunta viene dada por

$$F(x_1, \dots, x_p) = \Pr(X_1 \leq x_1, \dots, X_p \leq x_p).$$

Si la función es absolutamente continua, entonces $f(x_1, \dots, x_p)$ tal que

$$f(x_1, \dots, x_p) = \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_p} f(x_1, \dots, x_p) dx_1 \cdots dx_p$$

Si las variables X_1, \dots, X_p son independientes la obtención de $f(x_1, \dots, x_p)$, y de $F(x_1, \dots, x_p)$ se simplifica enormemente aplicando el teorema de factorización entre estos

$$f(x_1, \dots, x_p) = f_1(x_1) \cdots f_p(x_p)$$

$$F(x_1, \dots, x_p) = F_1(x_1) \cdots F_p(x_p)$$

No siempre puede llevarse a cabo este supuesto de independencia, depende de las condiciones del problema. En cualquier caso, en análisis multivariante no siempre se verifica la independencia entre las variables observadas. La densidad conjunta de cualesquier subconjunto de variables del conjunto original, se puede obtener mediante:

$$g(x_1, \dots, x_p) = \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_p} f(x_1, \dots, x_p) dx_{p+1} \cdots dx_{p+q}$$

para la función de densidad

$$g(x_1, \dots, x_p) = F(x_1, \dots, x_p, \infty, \dots, \infty)$$

Es importante que los límites de integración estén bien definidos, aunque formalmente no impide que sean definidos entre $-\infty$ y $+\infty$. Por ejemplo, para X_1, X_2 variables aleatorias i.i.d. con $f_{d,p}(x)$ y $f_d(y)$ si queremos obtener las f_{dp} y f_d de las otras variables

$$X_2 = \max(X_1, X_2)$$

$$X_1 = \min(X_1, X_2)$$

se obtiene fácilmente

$$f(x_1, x_2) = 2g(x_1)g(x_2) \quad -\infty < x_1 \leq x_2 < +\infty, 0 \text{ en el resto}$$

Las marginales vienen dadas por

$$f_1(x_1) = \int_{-\infty}^{+\infty} 2g(x_1)g(x_2) dx_2 = \int_{-\infty}^{x_1} 0 + \int_{x_1}^{+\infty} 2g(x_1)g(x_2) dx_2 = 2g(x_1)[1 - F(x_1)]$$

Análogamente

$$f_2(x_2) = \int_{-\infty}^{+\infty} 2g(x_1)g(x_2) dx_1 = \int_{-\infty}^{x_2} 2g(x_1)g(x_2) dx_1 + \int_{x_2}^{+\infty} 0 = 2g(x_2)g(x_2)$$

Observa además que $f(x_1, x_2) \neq f_1(x_1)f_2(x_2)$ no hay pris independencia.

Condicionales

Se trata de obtener la densidad de $\mathbf{X} - \mathbf{x}_p$ sabiendo que las otras variables han tomado un valor determinado $X_i = x_i \quad i = p+1, \dots, p+q$. Recordemos que dicha densidad viene dada por

$$h(x_1, \dots, x_p / x_{p+1}, \dots, x_{p+q}) = \frac{f(x_1, \dots, x_{p+q})}{g(x_{p+1}, \dots, x_{p+q})}$$

donde $f(x_1, \dots, x_{p+q})$ es la densidad conjunta y $g(x_{p+1}, \dots, x_{p+q})$ la marginal de las variables que condicionan. En el caso de independencia la condición se transforma simplemente en la marginal correspondiente. La función de distribución se obtiene mediante integración atendiendo las variables X_1, X_2 así definidas.

$$f(x_1/x_2) = \begin{cases} \frac{g(x_1)}{g(x_2)} & -\infty < x_1 \leq x_2 < \infty \\ 0 & \text{o en el resto} \end{cases}$$

la distribución correspondiente será

$$F(x_1/x_2) = \begin{cases} \frac{g(x_1)}{g(x_2)} & -\infty < x_1 \leq x_2 < \infty \\ 1 & x_2 \leq x_1 < \infty \end{cases}$$

Momentos

El vector media viene dado por

$$E(\mathbf{z}') = [E(z_1), \dots, E(z_p)]$$

La extensión del concepto de covarianza y varianza al caso multidimensional viene dado por

$$E\{[\mathbf{z} - E(\mathbf{z})][\mathbf{z} - E(\mathbf{z})]'\} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_{pp} \end{bmatrix} = \Sigma$$

Matriz que se denomina matriz de covarianzas de \mathbf{z}

Las expresiones matemáticas para las covarianzas y varianzas de determinadas combinaciones de variables vienen dadas

por:

$$a) \quad Y = a_1 z_1 + \dots + a_p z_p = a' \mathbf{z} \quad \text{var}(Y) = \text{var}(a' \mathbf{z}) = \sum \sum a_i a_j \sigma_{ij} = a' \Sigma a$$

$$b) \quad Y = a' \mathbf{z}, Z = b' \mathbf{z} \quad \text{corr}(Y, Z) = \left\{ \sum a_i b_j \sigma_{ij} \right\} = a' \Sigma b$$

$$c) \quad \text{Expresando de forma más general el cambio: } A \text{ matriz } r \times p \quad B \text{ matriz } s \times p$$

$$Y = A \mathbf{z} \quad Z = B \mathbf{z} \quad \text{entonces} \quad \text{corr}(Y, Y) = A \Sigma A'$$

$$\text{corr}(Z, Z) = B \Sigma B'$$

$$\text{corr}(Y, Z) = A \Sigma B'$$

Finalmente el coeficiente de correlación viene definido mediante

$$\rho_{ij} = \frac{\text{corr}(z_i, z_j)}{\sqrt{\text{var}(z_i) \cdot \text{var}(z_j)}}$$

la matriz de covariancia viene dada por:

$$\Sigma = \begin{bmatrix} 1 & \rho_{12} - \rho_{1P} \\ \rho_{12} - \rho_{1P} & 1 \end{bmatrix}$$

La relación existente entre los matrices de covarianza y de correlación viene dada por:

$$\rho = D\left(\frac{1}{\sigma_i}\right) \Sigma D\left(\frac{1}{\sigma_i}\right)$$

$$\Sigma = D(\sigma_i) P D(\sigma_i)$$

donde $D(\sigma_i)$ es la matriz diagonal de las desviaciones típicas de las variables.

2. LA DISTRIBUCIÓN NORMAL MULTIVARIANTE

En adelante las matrices a las que hagamos referencia provendrán de poblaciones normales multivariantes. Lo que pudiera considerarse como una verosimilitud puede justificarse en base a los siguientes razonamientos:

- a) Cualquier vector aleatorio que surja como la suma de un gran número de vectores aleatorios distribuidos idéntica e independientemente, tiene una distribución normal multivariante a medida que el número de estos vectores crece sin límite. Esto no es más que aplicar el torema central del límite en la versión multivariante. Este tipo de modelos sumas parece ser bastante realista a la hora de explicar gran parte de los fenómenos que surgen en Biología y en ciencias del comportamiento.
- b) Diferentes modelos para los vectores considerados podrían conducir a muy diferentes distribuciones conjuntas de los elementos ~~considerados~~, cuya complejidad matemática impide el desarrollo de las distribuciones multivariadas de los test estadísticos y de los standares usualmente. Tales distribuciones deberían ser consideradas para cada una de las poblaciones fundamentales del modelo. Sin embargo, parece probable que con la excepción de algunos casos patológicos, el teorema central del límite, en su versión multivariante garantice que las distribuciones para grandes muestras de los tests estadísticos conducirán a conclusiones similares acerca del estado de la naturaleza.

Hasta ~~esta~~ digamos, justificación del posterior uso, abuso de la normal multivariante razona con ella.

Recordemos que la distribución normal para el caso univariante tenía la expresión, en función de su densidad,

$$\phi(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right] \quad -\infty < x < \infty$$

Para el caso de n variables, x_1, \dots, x_n , todas normales e independientes tenemos:

$$\phi(x_1, \dots, x_n) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma_1^2 \dots \sigma_n^2} \exp\left[-\frac{1}{2} \sum_{i=1}^n \left(\frac{x_i - \mu_i}{\sigma_i}\right)^2\right]$$

y si escribimos

$$x' = [x_1, \dots, x_n] \quad \mu' = [\mu_1, \dots, \mu_n]$$

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \dots & 0 \\ \dots & \dots & \dots \\ 0 & \dots & \sigma_n^2 \end{bmatrix}$$

la densidad anterior adquiere la expresión

$$\phi(x) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left[-\frac{1}{2} z' \Sigma^{-1} z\right] \quad \text{con } z' = (x - \mu)' \quad z = (x - \mu)$$

~~Definición de la densidad multivariante~~

Esta expresión es una expresión particular de la densidad de una variable multivariante, porque, en efecto, no siempre el vector x considerado está constituido por variables aleatorias independientes. La generalización de la anterior expresión obtiene haciendo que Σ sea una matriz simétrica definida positiva, entonces la función $\phi(x)$ es positiva para cualquier valor de x que cumplga ademas que

$$\int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} \phi(x_1, \dots, x_n) dx_1 \cdots dx_n = 1$$

es decir, $\phi(x)$ > una función de densidad. En esta, indicamos tenemos que:

- el i -ésimo elemento del vector μ es la esperanza de x_i .
- el i -ésimo elemento de la diagonal principal de Σ es la varianza de x_i .
- el ij -ésimo elemento, ρ_{ij} , de la matriz Σ es la covarianza de x_i y x_j . Claramente si las $P(p-1)/2$ covarianzas son nulas, entonces los x_i son independientes.

Consideremos con algún detalle el caso $n=2$, de gran importancia en estadística técnica.

$$\mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{12} & \sigma_{22} \end{bmatrix} = \begin{bmatrix} \sigma_{11} & \rho \sigma_{11} \sigma_{22} \\ \rho \sigma_{11} \sigma_{22} & \sigma_{22} \end{bmatrix}$$

La densidad conjunta será

$$\phi(x_1, x_2) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2} \frac{1}{1-\rho^2} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \frac{x_1 - \mu_1}{\sigma_1} \cdot \frac{x_2 - \mu_2}{\sigma_2} + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right] \right\}$$

Si tipificamos las variables mediante la transformación

$$z_i = \frac{x_i - \mu_i}{\sigma_i}, \text{ tenemos}$$

$$\phi(z_1, z_2) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2} \frac{1}{1-\rho^2} \left[z_1^2 - 2\rho z_1 z_2 + z_2^2 \right] \right\}$$

Posteriormente veremos sobre la densidad yaremos enfocar el papel de ρ .

Ejes principales en la densidad multivariante

el exponente

$$(x - \mu)' \Sigma^{-1} (x - \mu)$$

es una función cuadrática y por tanto define la ecuación de un elipsoidal en el espacio n -dimensional cuando los igualamos a alguna constante positiva. La familia de elipsoides que se genera cuando los igualamos a distintos valores, c , de esta constante recorre todo proyectando todos ellos están centrados en μ . El eje principal del elipsoidal es aquella línea que pasa atraves de su mayor dimensión. Si representamos a cualquier de las líneas que pasan por μ , mediante su punto de corte en la superficie del elipsoidal, el eje principal tendrá una pendiente que maximizará la longitud del segmento que μ y x determinan. El cuadrado de dicha longitud viene dado por

$$(x - \mu)' (x - \mu)$$

El cálculo de este primer je vendrá más tarde mediante la resolución de un problema de máximos condicionados. A saber, maximizar

$$(x - \mu)' (x - \mu)$$

sujeto a la restricción

$$(x - \mu)' \Sigma^{-1} (x - \mu) = c$$

Regularizando con los multiplicadores de Lagrange, tendremos

$$f(x) = (x - \mu)^T (x - \mu) - \lambda [(x - \mu)^T \Sigma^{-1} (x - \mu) - c]$$

y derivando

$$\frac{\partial f(x)}{\partial x} = 2(x - \mu) - 2\lambda \Sigma^{-1} (x - \mu) = 2[I - \lambda \Sigma^{-1}] (x - \mu) \neq$$

e igualando a cero

$$[I - \lambda \Sigma^{-1}] (x - \mu) = 0$$

Es decir, que las coordenadas del eje mayor deben satisfacer la anterior ecuación, que como Σ^{-1} es no singular, admite también la forma:

$$[\Sigma - \lambda I] (x - \mu) = 0$$

Lo que da a entender que las coordenadas del eje principal son proporcionales a los dos vectores características de Σ . Pero veamos a cuál. Si premultiplicamos por $4(x - \mu)^T$, tendremos:

$$4(x - \mu)^T [\Sigma - \lambda I] (x - \mu) = 0$$

$$4(x - \mu)^T (x - \mu) = 4\lambda c$$

Por tanto para c fijo la longitud del eje principal es maximizada tomando λ igual a la mayor de las raíces características de Σ . Por tanto podemos afirmar:

"La posición del primer eje principal del elipsoidal de concentración viene especificada por los dos directores del vector característico mayorizado al ser añadido a la mayor raíz característica λ_1 de Σ ".

Obsérvese que la longitud del eje viene entonces dada por $\lambda = 2\sqrt{\lambda_1 c}$

El segundo eje principal vendrá dado por λ_2 , cuando dicho valor sea la segunda mayor raíz característica de Σ . El proceso se sigue hasta obtener los n ejes principales del elipsoidal.

Si las raíces características son distintas todas ellas,

$$\lambda_1 > \lambda_2 > \dots > \lambda_n > \lambda_{n+1}$$

entonces, recordando una propiedad que asegura que los vectores asociados son ortogonales

$$\alpha_i^T \alpha_j = 0 \quad , \quad \lambda_i \neq \lambda_j$$

Tendremos que los n ejes están univocamente determinados y ademas, no todos ellos permanecen entre sí. Si hubieran dos raíces consecutivas iguales, quisiera decir, que el elipsoidal tiene una dirección similar a la del plano que las direcciones de los vectores asociados correspondiente determinan. En este caso, aunque pueden encontrarse ejes perpendiculares entre si, se produciría en el elipsoidal un absurdo. Sin embargo, en general si λ_i es una raíz característica, cuya orden de multiplicidad es r_i , cada uno de los r_i ejes a determinar puede ser elegido perpendicular a los $r_i - 1$ restantes que son los $n - r_i$, aunque dichos ejes pueden comprender una infinitud de direcciones principales. En tal caso, el elipsoidal tiene forma hiperbolica en el subespacio que determinan las r_i raíces características y reduce que tiene variancia isotropica en este subespacio. Posteriormente nos interesarán unicamente se tiene cuando la relación ρ sea una determinada medida estadística.

Consideremos ahora la otra variable $\mathbf{Y}' = [y_1 \dots y_n]$ cuyos elementos tienen valores en los ejes principales del elipsóide de concentración. Esta variable se obtiene en el vector original \mathbf{x} , mediante la transformación

$$\mathbf{y} = \mathbf{A}'(\mathbf{x} - \mu)$$

donde la i-ésima columna de la matriz \mathbf{A} es el vector característico normalizado α_i . La ortogonalidad de \mathbf{A} implica que la transformación consiste en una rotación rígida de los ejes originales hasta coincidir con los ejes principales del elipsóide seguida de un traslado del antiguo centro al centro de del elipsóide. La matriz de covarianzas del nuevo vector \mathbf{y} vendrá dada por

$$\Sigma_y = \mathbf{A}' \Sigma \mathbf{A}$$

que como sabemos es una matriz diagonal cuyos valores (esa la diagonal principal son) λ_i . Por tanto la varianza de la variable que se mueve en el i-ésimo eje principal vendrá dada por

$$\text{Var}(y_i) = \alpha_i' \Sigma \alpha_i = \lambda_i$$

por tanto

$$\text{Cov}(y_i y_j) = \alpha_i' \Sigma \alpha_j = 0 \quad i \neq j$$

a condición de que todas las λ_i sean distintas o bien, en caso contrario, los α_i no hayan dejado ortogonal.

Así pues la transformación de los ejes principales da lugar a variables secundarias cuyas varianzas son proporcionales a la longitud de los ejes (a medida más exactamente).

Aplicaremos este método a la forma elíptica con los componentes tipificados por aquello de la multiplicidad.

~~Definiremos la familia de elipsoides (elipses, alíes) mediante~~

$$h = \phi(z_1 z_2)$$

Su ecuación vendrá dada por

$$(1-\rho^2)c = z_1^2 - 2\rho z_1 z_2 + z_2^2$$

con $c = -2 \log(2\pi h \sqrt{1-\rho^2})$. Las raíces características de

$$\Sigma = \begin{bmatrix} 1 & \rho \\ \rho & 1 \end{bmatrix}$$

y los vectores canónicos $\alpha'_1 = [\frac{1}{2}\sqrt{2}, \frac{1}{2}\sqrt{2}]$, $\alpha'_2 = [\frac{1}{2}\sqrt{2}, -\frac{1}{2}\sqrt{2}]$.

Si ρ es positivo el eje principal mayor es la línea $z_1 = z_2$ y el menor la línea $z_1 = -z_2$. En caso contrario se invierten los ejes. Cuando $\rho = 0$, la elipse es un círculo y existen una infinitud de ejes principales, indistintos entre sí y todos de las variables originales. Señalemos por último que en este caso particular en que las varianzas son iguales (e iguales a 1) los ejes tienen la misma posición, independientemente del valor que tome ρ .

3. DISTRIBUCIONES MARGINALES Y CONDICIONALES DE LAS VARIABLES MULTINORMALES

Comenzaremos demostrando una proposición de utilidad posterior para determinar la distribución marginal de cualquier subconjunto de variables del vector $\mathbf{x} = (x_1, \dots, x_n)$.

PROPOSICIÓN. Si \mathbf{Z} es un vector aleatorio con n componentes con una distribución normal multivariante. Entonces

$$\mathbf{y} = \mathbf{C}\mathbf{Z}$$

se distribuye como $N(\mathbf{C}\mu, \mathbf{C}\Sigma\mathbf{C}')$ para \mathbf{C} no singular.

Demostración.- Recordemos que la densidad de \mathbf{Y} se obtiene a partir de la densidad de \mathbf{X} , empleando

$x \sim \text{prior}$

$$\mathbf{x} = \mathbf{C}^{-1} \mathbf{y}$$

y multiplicando por el Jacobiano de la transformación. Recordemos que en el caso de una transformación lineal viene dado por $\det |\mathbf{C}^{-1}|$. Recordemos que

$$\det |\mathbf{C}^{-1}| = \frac{1}{\det |\mathbf{C}|} = \sqrt{\frac{1}{|\mathbf{C}|^2}} = \sqrt{\frac{|\Sigma|}{|\mathbf{C}| \cdot |\Sigma| \cdot |\mathbf{C}|}} = \frac{|\Sigma|^{1/2}}{|\mathbf{C} \Sigma \mathbf{C}^T|^{1/2}}$$

la primera medición del exponente $\mathcal{Q} = (\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})$ se transformaría en

$$\begin{aligned} \mathcal{Q} &= (\mathbf{C}^{-1} \mathbf{y} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{C}^{-1} \mathbf{y} - \boldsymbol{\mu}) = (\mathbf{C}^{-1} \mathbf{y} - \mathbf{C}^{-1} \mathbf{C} \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{C}^{-1} \mathbf{y} - \mathbf{C}^{-1} \mathbf{C} \boldsymbol{\mu}) = \\ &= [\mathbf{C}^{-1} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu})]^T \Sigma^{-1} [\mathbf{C}^{-1} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu})] = (\mathbf{y} - \mathbf{C} \boldsymbol{\mu})^T (\mathbf{C}^{-1})^T \Sigma^{-1} \mathbf{C}^{-1} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu}) = \\ &= (\mathbf{y} - \mathbf{C} \boldsymbol{\mu})^T (\mathbf{C} \Sigma \mathbf{C}^T)^{-1} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu}) \end{aligned}$$

la densidad de \mathbf{Y} vendrá entonces dada por

$$\begin{aligned} f(\mathbf{y}) &= \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{1/2}} \cdot \frac{\Sigma^{1/2}}{|\mathbf{C} \Sigma \mathbf{C}^T|^{1/2}} \cdot \exp \left\{ -\frac{1}{2} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu})^T (\mathbf{C} \Sigma \mathbf{C}^T)^{-1} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu}) \right\} = \\ &= \frac{1}{(2\pi)^{\frac{n}{2}} |\mathbf{C} \Sigma \mathbf{C}^T|^{1/2}} \cdot \exp \left\{ -\frac{1}{2} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu})^T (\mathbf{C} \Sigma \mathbf{C}^T)^{-1} (\mathbf{y} - \mathbf{C} \boldsymbol{\mu}) \right\}. \end{aligned}$$

lo que demuestra la proposición.

Veamos ahora de estudiar las marginales. Tomamos para ello a dividir el conjunto de variable en dos subconjuntos $\mathbf{x}_1, \dots, \mathbf{x}_q, \mathbf{y}, \mathbf{x}_{q+1}, \dots, \mathbf{x}_n$ y formaremos los vectores

$$\mathbf{x}^{(1)} = \begin{bmatrix} \mathbf{x}_1 \\ | \\ \mathbf{x}_q \end{bmatrix}, \quad \mathbf{x}^{(2)} = \begin{bmatrix} \mathbf{x}_{q+1} \\ | \\ \mathbf{x}_n \end{bmatrix}$$

de manera que

$$(1) \quad \mathbf{x} = \begin{bmatrix} \mathbf{x}^{(1)} \\ \mathbf{x}^{(2)} \end{bmatrix} = \begin{bmatrix} \mathbf{x}_1 \\ | \\ \mathbf{x}_n \end{bmatrix}$$

Supongamos además que las variables que representan el vector \mathbf{x} tienen una distribución conjunta normal multivariante con media

$$\mathbb{E}(\mathbf{x}^{(1)}) = \boldsymbol{\mu}^{(1)}, \quad \mathbb{E}(\mathbf{x}^{(2)}) = \boldsymbol{\mu}^{(2)}$$

y covarianzas

$$\mathbb{E}((\mathbf{x}^{(1)} - \boldsymbol{\mu}^{(1)})(\mathbf{x}^{(1)} - \boldsymbol{\mu}^{(1)})^T) = \Sigma_{11}$$

$$\mathbb{E}((\mathbf{x}^{(2)} - \boldsymbol{\mu}^{(2)})(\mathbf{x}^{(2)} - \boldsymbol{\mu}^{(2)})^T) = \Sigma_{22}$$

$$\mathbb{E}((\mathbf{x}^{(1)} - \boldsymbol{\mu}^{(1)})(\mathbf{x}^{(2)} - \boldsymbol{\mu}^{(2)})^T) = \Sigma_{12} = \Sigma_{21}^T = 0.$$

Decimos entonces que el vector \mathbf{x} ha sido fraccionado en (1) en dos subvectores, que el vector media ha sido fraccionado armónicamente en subvectores y que la matriz de covarianzas

$$\Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix} = \begin{bmatrix} \Sigma_{11} & 0 \\ 0 & \Sigma_{22} \end{bmatrix}$$

ha sido fraccionada, análogamente en matrices.

bueno a demostrar ahora que en las condiciones anteriormente impuestas las matrices de Σ , las variables $\bar{x}^{(1)}$ y $\bar{x}^{(2)}$ se distribuyen independientes y normalmente.

la inversa de Σ vendrá dada por

$$\Sigma^{-1} = \begin{bmatrix} \Sigma_{11}^{-1} & 0 \\ 0 & \Sigma_{22}^{-1} \end{bmatrix}$$

en cuanto a la forma cuadrática del cociente, tenemos

$$\begin{aligned} Q &= (\bar{x} - \mu)^T \Sigma^{-1} (\bar{x} - \mu) = \left[(\bar{x}^{(1)} - \mu^{(1)})^T, (\bar{x}^{(2)} - \mu^{(2)})^T \right] \begin{bmatrix} \Sigma_{11}^{-1} & 0 \\ 0 & \Sigma_{22}^{-1} \end{bmatrix} \begin{bmatrix} (\bar{x}^{(1)} - \mu^{(1)}) \\ (\bar{x}^{(2)} - \mu^{(2)}) \end{bmatrix} = \\ &= \left[(\bar{x}^{(1)} - \mu^{(1)})^T \Sigma_{11}^{-1}, (\bar{x}^{(2)} - \mu^{(2)})^T \Sigma_{22}^{-1} \right] \begin{bmatrix} \bar{x}^{(1)} - \mu^{(1)} \\ \bar{x}^{(2)} - \mu^{(2)} \end{bmatrix} = \\ &= (\bar{x}^{(1)} - \mu^{(1)})^T \Sigma_{11}^{-1} (\bar{x}^{(1)} - \mu^{(1)}) + (\bar{x}^{(2)} - \mu^{(2)})^T \Sigma_{22}^{-1} (\bar{x}^{(2)} - \mu^{(2)}) = Q_1 + Q_2 \end{aligned}$$

por otra parte $|\Sigma| = |\Sigma_{11}| \cdot |\Sigma_{22}|$. Entonces la densidad de \bar{x} podremos escribir como

$$f(\bar{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \cdot e^{-\frac{1}{2}Q} = \frac{1}{(2\pi)^{\frac{n_1}{2}} |\Sigma_{11}|^{\frac{1}{2}}} \cdot e^{-\frac{1}{2}Q_1} \cdot \frac{1}{(2\pi)^{\frac{n_2}{2}} |\Sigma_{22}|^{\frac{1}{2}}} \cdot e^{-\frac{1}{2}Q_2} = f(\bar{x}^{(1)}) \cdot f(\bar{x}^{(2)})$$

que es el producto de dos normas multivariantes, a saber, $N(\mu^{(1)}, \Sigma_{11}) \cdot N(\mu^{(2)}, \Sigma_{22})$.

la marginal de $\bar{x}^{(1)}$ vendrá dada por la integral

$$\int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} f(\bar{x}) dx_{q+1} \cdots dx_n = f(\bar{x}^{(1)}) \cdot \int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} f(\bar{x}^{(2)}) dx_{q+1} \cdots dx_n = f(\bar{x}^{(1)})$$

es decir, la marginal de $\bar{x}^{(1)}$ es una $N(\mu^{(1)}, \Sigma_{11})$. Análogamente establecemos $N(\mu^{(2)}, \Sigma_{22})$ para la marginal de $\bar{x}^{(2)}$ y como además $N(\mu, \Sigma)$ puede factorizarse como producto de ambas marginales podemos afirmar que ambas variables son independientes, podemos enunciar el siguiente teorema:

TEOREMA - Si $\bar{x}_1, \dots, \bar{x}_n$ tienen una densidad conjunta normal multivariante, una condición necesaria y suficiente para que los subconjuntos de estas variables y los subconjuntos complementarios sean independientes es que cada covarianza de una variable de un conjunto y una variable del otro sea nula.

la veracidad se deduce de inmediato teniendo en cuenta que

$$\sigma_{ij} = E((\bar{x}_i - \mu_i)(\bar{x}_j - \mu_j)) = \int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} (\bar{x}_i - \mu_i)(\bar{x}_j - \mu_j) f(\bar{x}^{(1)}) f(\bar{x}^{(2)}) \cdots d\bar{x}^{(1)} d\bar{x}^{(2)} =$$

$$= \left\{ \int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} (\bar{x}_i - \mu_i) f(\bar{x}^{(1)}) d\bar{x}^{(1)} \right\} \left\{ \int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} (\bar{x}_j - \mu_j) f(\bar{x}^{(2)}) d\bar{x}^{(2)} \right\} = 0.$$

por tanto $\sigma_{ij} = 0$ y vendremos que independencia e independencia son equivalentes en el caso de normalidad.

Consideremos el caso especial en que se trata de una normal multivariante. Es decir

2(5)

$$\mathbf{X}^{(1)} = \mathbf{x}_1, \mathbf{X}^{(2)} = \mathbf{x}_2, \mu^{(1)} = \mu_1, \mu^{(2)} = \mu_2, \Sigma_{11} = \sigma_{11}^2 = \sigma_1^2, \Sigma_{22} = \sigma_{22}^2 = \sigma_2^2, \Sigma_{12} = \Sigma_{21} = \sigma_{12} = \sigma_1 \sigma_2 \rho_{12}.$$

Aquí, si $\mathbf{x}_1, \mathbf{x}_2$ tienen distribución normal bivariante con varianas independientes entre sí y covarianza σ_{12}^2 . De este caso la marginal de \mathbf{x}_1 es una normal con media μ_1 y varianza σ_1^2 . Podemos concluir el siguiente

COROLARIO - Si \mathbf{x} es un vector normal multivariante $N(\mu, \Sigma)$ y si se elimina de \mathbf{x} las variables con otro conjunto (el complementario), la distribución marginal del conjunto es una normal multivariante con medias, varianas y covarianas obtenidas tomando las correspondientes componentes de μ y Σ respectivamente.

Pero vamos a ir más allá en estos resultados. Hacemos a comprobar que estos resultados son válidos aún cuando los subvectores obtenidos no sean independientes. Hacemos para ello la siguiente transformación lineal no singular de los subvectores,

$$Y^{(1)} = \mathbf{x}^{(1)} + M \mathbf{x}^{(2)}$$

$$Y^{(2)} = \mathbf{x}^{(2)}$$

eligiendo M de tal manera que las componentes de $Y^{(1)}$ sean independientes con las componentes de $Y^{(2)} = \mathbf{x}^{(2)}$. La matriz M debe satisfacer, para ello, la siguiente ecuación

$$\begin{aligned} 0 &= E((Y^{(1)} - E(Y^{(1)}))(Y^{(2)} - E(Y^{(2)}))^\top = E((\mathbf{x}^{(1)} + M\mathbf{x}^{(2)} - E(\mathbf{x}^{(1)}))(\mathbf{x}^{(2)} - E(\mathbf{x}^{(2)}))^\top = \\ &= E((\mathbf{x}^{(1)} - E(\mathbf{x}^{(1)})) + (M\mathbf{x}^{(2)} - M E(\mathbf{x}^{(2)}))) (\mathbf{x}^{(2)} - E(\mathbf{x}^{(2)}))^\top = \Sigma_{12} + M\Sigma_{22} \end{aligned}$$

y de aquí

$$M = -\Sigma_{12} \Sigma_{22}^{-1}$$

$$\text{y por tanto } Y^{(1)} = \mathbf{x}^{(1)} - \Sigma_{12} \Sigma_{22}^{-1} \mathbf{x}^{(2)}.$$

Es decir

$$\mathbf{y} = \begin{bmatrix} Y^{(1)} \\ Y^{(2)} \end{bmatrix} = \begin{bmatrix} I & -\Sigma_{12} \Sigma_{22}^{-1} \\ 0 & I \end{bmatrix} \begin{bmatrix} \mathbf{x}^{(1)} \\ \mathbf{x}^{(2)} \end{bmatrix} = \begin{bmatrix} I & -\Sigma_{11} \Sigma_{22}^{-1} \\ 0 & I \end{bmatrix} \mathbf{x}$$

Si una transformación no singular de \mathbf{x} , tendría por tanto, de acuerdo con la primera proposición, una distribución normal dada por

$$E \begin{bmatrix} Y^{(1)} \\ Y^{(2)} \end{bmatrix} = \begin{bmatrix} I & -\Sigma_{12} \Sigma_{22}^{-1} \\ 0 & I \end{bmatrix} \begin{bmatrix} \mu^{(1)} \\ \mu^{(2)} \end{bmatrix} = \begin{bmatrix} \mu^{(1)} - \Sigma_{12} \Sigma_{22}^{-1} \mu^{(2)} \\ \mu^{(2)} \end{bmatrix} = \begin{bmatrix} \mu^{(1)} \\ \nu^{(2)} \end{bmatrix} = \mathbf{v}$$

y matriz de covarianzas

$$C(\mathbf{y}, \mathbf{y}) = \begin{bmatrix} I & -\Sigma_{12} \Sigma_{22}^{-1} \\ 0 & I \end{bmatrix} \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix} \begin{bmatrix} I & 0 \\ -\Sigma_{12} \Sigma_{22}^{-1} & I \end{bmatrix} = \begin{bmatrix} \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} & 0 \\ 0 & \Sigma_{22} \end{bmatrix}$$

Notar entonces que de acuerdo con el teorema anterior $Y^{(1)}$ e $Y^{(2)}$ son independientes y aplicando el corolario $\mathbf{x}^{(2)} = \mathbf{y}^{(2)}$ tiene como marginal una normal $N(\mu^{(2)}, \Sigma_{22})$. Podemos entonces enunciar el siguiente teorema

TEOREMA - Si \mathbf{x} tiene una distribución normal multivariante $N(\mu, \Sigma)$, la marginal de cualquier subconjunto de componentes de \mathbf{x} es normal multivariante con medias, varianas y covarianas obtenidas tomando las correspondientes componentes de μ y Σ respectivamente.

Consideremos ahora la transformación

$$Z = D\bar{X}$$

donde Z tiene q componentes y D es una matriz real $q \times n$. El valor esperado de Z viene dado por

$$E(Z) = D\mu.$$

y su matriz de covarianzas es

$$E((Z - D\mu)(Z - D\mu)^T) = D\Sigma D^T$$

El caso $q=n$, D no singular ya lo studiamos al comienzo de este párrafo. Si $q \leq n$, D de rango q , podemos encontrar una matriz E , $(n-q) \times n$ de tal forma que

$$\begin{pmatrix} Z \\ W \end{pmatrix} = \begin{pmatrix} D \\ E \end{pmatrix} \bar{X}$$

una transformación no singular. En este caso Z, W tienen distribución conjunta normal multivariante y Z de acuerdo con el teorema anterior tendrá una marginal normal cuyos parámetros ya conocemos. Tenemos en consecuencia la siguiente tesis:

Teorema - Si \bar{X} es un vector normal multivariante $N(\mu, \Sigma)$, entonces $Z = D\bar{X}$ se distribuye $N(D\mu, D\Sigma D^T)$, donde D es una matriz real $q \times n$ de rango $q \leq n$.

Podría ser posible obtener a través de una generalización de este teorema para aquellos casos en que D sea una matriz cualquiera, no necesariamente de rango completo. En cualquier caso los resultados de ello serían igualmente.

Distribuciones condicionales

Queremos tratar de encontrar las distribuciones condicionales derivadas de una normal multivariante.

Sea \bar{X} un vector normal multivariante $N(\mu, \Sigma)$ con Σ no singular. Si queremos acabo la partición en dos

subvectores

$$\bar{X} = \begin{bmatrix} \bar{x}^{(1)} \\ \bar{x}^{(2)} \end{bmatrix}$$

de q y $n-q$ componentes respectivamente. Recordemos que en el párrafo anterior obtenímos la distribución conjunta de las variables $Y^{(1)} = \bar{x}^{(1)} - \Sigma_{12}\Sigma_{22}^{-1}\bar{x}^{(2)}$ e $Y^{(2)} = \bar{x}^{(2)}$, cuya expresión era un producto de momentos,

$$n(Y^{(1)} | \mu^{(1)}, \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\mu^{(2)}, \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}) \cdot n(Y^{(2)} | \mu^{(2)}, \Sigma_{22})$$

La densidad conjunta de $\bar{x}^{(1)}$ y $\bar{x}^{(2)}$ podemos obtenerla a partir de la anterior expresión, sustituyendo $\bar{x}^{(1)}$ por $x^{(1)} - \Sigma_{12}\Sigma_{22}^{-1}x^{(2)}$ y $\bar{x}^{(2)}$ por $x^{(2)}$ teniendo en cuenta que el Jacobiano de la transformación es 1. El resultado de esta sustitución será:

$$f(x^{(1)}, x^{(2)}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_{11,2}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} \left[(x^{(1)} - \mu^{(1)}) - \Sigma_{12}\Sigma_{22}^{-1}(x^{(2)} - \mu^{(2)}) \right]^T \Sigma_{11,2}^{-1} \left[(x^{(1)} - \mu^{(1)}) - \Sigma_{12}\Sigma_{22}^{-1}(x^{(2)} - \mu^{(2)}) \right] \right\}$$
$$\cdot \frac{1}{(2\pi)^{\frac{n-q}{2}} |\Sigma_{22}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} \left[(x^{(2)} - \mu^{(2)}) \right]^T \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)}) \right\}$$

$$\text{donde } \Sigma_{11,2} = \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}.$$

Expresión ésta que deseamos minimizar, más bien, en la de la densidad de \bar{X} , es decir $n(\bar{x} | \mu, \Sigma)$. El efecto de la factorización anterior quedará de manifiesto a continuación. De hecho, la densidad condicional de $\bar{x}^{(1)}$ dado que $\bar{x}^{(2)} = x^{(2)}$ es igual al cuociente de la anterior expresión y la densidad marginal de $\bar{x}^{(2)}$, que es precisamente el segundo factor.

Así pues

$$f(x^{(1)}/x^{(2)}) = \frac{1}{(2\pi)^{\frac{q}{2}} |\Sigma_{11,2}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} [(x^{(1)} - \mu^{(1)}) - \sum_{12} \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)})]^T [\Sigma_{11,2}^{-1} ((x^{(1)} - \mu^{(1)}) - \sum_{12} \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)})] \right\}.$$

claramente, la densidad $f(x^{(1)}/x^{(2)})$ es una densidad normal q-variente con vector media

$$E(x^{(1)}/x^{(2)}) = \mu^{(1)} + \sum_{12} \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)}) = \nu(x^{(1)})$$

y matriz de covariancia

$$E[(x^{(1)} - \nu(x^{(1)})) (x^{(1)} - \nu(x^{(1)}))^T] = \Sigma_{11,2} = \Sigma_{11} - \sum_{12} \Sigma_{22}^{-1} \Sigma_{21}.$$

Hay que destacar en estas expresiones que la media de $x^{(1)}$ dado $x^{(2)}$ es simplemente una función lineal de $x^{(2)}$ mientras que la matriz de covariancia, comprendida por el coeficiente de regresión, no depende para nada de $x^{(2)}$.

DEFINICIÓN. - La matriz $\Sigma_{12} \Sigma_{22}^{-1}$ se llama matriz de regresión de $x^{(1)}$ sobre $x^{(2)}$.

El i,j-simo elemento de $\Sigma_{12} \Sigma_{22}^{-1}$ viene a menudo representado por

$$\beta_{ij}, \quad i=1, \dots, q; \quad j=1, \dots, n$$

Al vector $\mu^{(1)} + \sum_{12} \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)})$ se le denomina función de regresión.

Si por $\sigma_{ij, q+1, \dots, n}$ designamos el elemento i,j-simo de $\Sigma_{11,2}$, llamaremos a esta cantidad covarianza parcial.

DEFINICIÓN. -

$$\rho_{ij, q+1, \dots, n} = \frac{\sigma_{ij, q+1, \dots, n}}{\sqrt{\sigma_{ii, q+1, \dots, n}} \cdot \sqrt{\sigma_{jj, q+1, \dots, n}}} \quad i, j = 1, \dots, q$$

es el coeficiente de covarianza parcial entre x_i y x_j cuando x_{q+1}, \dots, x_n permanecen fijas.

DEFINICIÓN. - Al vector aleatorio

$$x_{1,2} = x^{(1)} - \mu^{(1)} - \sum_{12} \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)})$$

se le llama el conjunto de las variables residuales, y representa los desvíos de los elementos de $x^{(1)}$ y de la predicción de sus valores media a partir de la relación lineal del vector media de la distribución condicional con las variables de $x^{(2)}$.

Como ya vimos anteriormente

$$\text{cor}(y^{(1)}, y^{(2)}) = 0 \rightarrow \text{cor}(x_{1,2}, x^{(1)}) = 0$$

mientras que

$$\text{cor}(y^{(1)}, y^{(2)}) = \Sigma_{11,2} \rightarrow \text{var}(x_{1,2}, x^{(2)}) = \Sigma_{11,2}$$

Como la numeración de los componentes de x es arbitraria y q también lo es, todo lo anterior sirve para definir la distribución condicional de cualquier conjunto de q componentes de x , fijando los n-q restantes. Analogamente, dado que la marginal de cualesquier r componentes de x es normal, podemos también definir la distribución condicional de cualesquier q componentes (q < r) dado que los restantes r-q permanecen fijas. Podemos enunciar el siguiente teorema.

TEOREMA. - Sea x un vector aleatorio multidimensional dividido en los grupos cojugados que dan lugar a los subvectores $x^{(1)}$, $x^{(2)}$. Supongamos que dividirlos a la media pu de forma similar $\mu^{(1)}$, $\mu^{(2)}$ y que la matriz de covariancias Σ aparece dividida en las submatrices $\Sigma_{11}, \Sigma_{12}, \Sigma_{22}$ que son las matrices de covariancia de $x^{(1)}$, de $x^{(1)}$, $x^{(2)}$, de $x^{(2)}$ respectivamente. Entonces, si la distribución de x es normal, la distribución condicional de $x^{(1)}$ dado $x^{(2)} = x^{(2)}$ es también normal con media $\mu^{(1)} + \sum_{12} \Sigma_{22}^{-1} (x^{(2)} - \mu^{(2)})$ y matriz de covariancias $\Sigma_{11,2} = \Sigma_{11} - \sum_{12} \Sigma_{22}^{-1} \Sigma_{21}$.

Consideremos, como un ejemplo de todo lo expuesto el caso de una variable bivariante y vamos a encontrar la condicional de X_1 , dado $X_2 = x_2$. En este caso $\mu^{(1)} = \mu_1$, $\mu^{(2)} = \mu_2$, $\Sigma_{11} = \sigma_1^2$, $\Sigma_{12} = \rho \sigma_1 \sigma_2$, $\Sigma_{22} = \sigma_2^2$. La matriz de los coeficientes de regresión vendrá dada por $\Sigma_{12} \Sigma_{22}^{-1} = \rho \sigma_1 / \sigma_2$, y la matriz de covarianzas parciales será

$$\Sigma_{11|2} = \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} = \sigma_1^2 - \rho \sigma_1 \sigma_2 \cdot \frac{1}{\sigma_2^2} \cdot \rho \sigma_1 \sigma_2^2 = \sigma_1^2 - \rho^2 \sigma_1^2 = \sigma_1^2 (1 - \rho^2)$$

entonces la densidad del X_1 , dado $X_2 = x_2$ será

$$f(x_1|x_2) = \frac{1}{[2\pi \sigma_1^2(1-\rho^2)]^{1/2}} \exp \left\{ -\frac{1}{2} (x_1 - \mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2))^2 / \sigma_1^2 (1 - \rho^2) \right\}$$

Hay que hacer notar que para valores de ρ positivos, la media condicional aumenta a medida que lo hace x_2 y disminuye si ρ es negativo.

Algunas consideraciones geométricas

Una interpretación geométrica de la teoría expuesta puede ayudar a comprenderla mejor. La densidad $f(x_1, x_2)$ puede ser considerada como una superficie $z = f(x_1, x_2)$ sobre el plano x_1, x_2 . Si intersecamos esta superficie mediante el plano $x_2 = c$ obtenemos una curva $z = f(x_1, c)$ sobre la línea $x_2 = c$ en el plano x_1, x_2 . Las ordenadas de esta curva son proporcionales a la densidad condicional de X_1 , dado $X_2 = x_2$; es decir, proporcionales a las ordenadas de la curva de una distribución normal univariante. En el caso más general, y considerando el espacio n -dimensional, las superficies de densidad constante de $f(x_1 - x_q / c_{q+1}, \dots, x_n)$, las hiperplanos $x_{q+1} = c_{q+1} - \dots - x_n = c_n$. Estas son también disjointas.

Para una mayor claridad de las ideas puestas, haremos algunas consideraciones acerca de una población ideal idealizada mediante una distribución normal. Consideremos por ejemplo una población de parejas padre-hijo. Si la población es totalmente homogénea, las alturas de los padres y las alturas de los hijos tendrían aproximadamente una distribución normal. Una distribución condicional puede obtenerse considerando a los hijos de aquellos padres cuya altura sea, por ejemplo, 175 cms. Las alturas de estos hijos tendrían una distribución aproximadamente normal ~~multidimensional~~ univariante. La media de esta distribución difiere de la media de las alturas de los hijos cuyos padres tienen una altura de 175 cms, por ejemplo, pero las varianzas serían las mismas.

Consideremos también las tripetas constituidas por las alturas de un padre y sus dos hijos mayores. La relación de alturas de ambos hijos para padres de 175 cms. de altura. La distribución condicional de dos variables: la correlación entre las alturas de los dos hijos mayores & un coeficiente de correlación parcial. El hecho de mantener constante la altura de los padres elimina el efecto hereditario debido a los mismos. No obstante, cabría esperar una correlación positiva entre ambas alturas puesto que los efectos hereditarios de la madre y los ambientales tienden a causar en las alturas de los humanos ~~efectos~~ variaciones similares (de la misma medida).

Como hemos visto anteriormente, una distribución condicional obtenida a partir de una distribución normal es normal con media una función lineal de las variables fijadas y matriz de covarianzas constante. En el caso de distribuciones no normales la distribución condicional de un conjunto de variables sobre otra no tiene usualmente esta propiedad. No obstante, pueden construirse distribuciones nominales tales que algunas distribuciones condicionales tengan la citada propiedad. Esto puede hacerse tomando como densidad para X el producto $\alpha(x/\mu^{(1)} + \beta(x^{(2)} - \mu^{(2)}), \Sigma_{11|2}) f(x^{(2)})$ donde $f(x^{(2)})$ es una densidad cualquiera.

El coeficiente de correlación multiple

Consideremos nuevamente \mathbf{x} fraccionado en $\mathbf{x}^{(1)}$, $\mathbf{x}^{(2)}$. Vamos a estudiar algunas propiedades de $\Sigma_{12} \Sigma_{22}^{-1} \Sigma_{22}$.

Como solo estamos interesados, ahora, en función de las covarianzas y stas con variancia por cuenta de origen o de escala vamos a suponer $\mu=0$. Elijamos \mathbf{x}_i una componente de $\mathbf{x}^{(1)}$. Entonces

$$\mathbb{E}(\mathbf{x}_i / \mathbf{x}^{(2)}) = \beta \mathbf{x}^{(2)}$$

$$\text{donde } \beta = \sigma_{(i)} \Sigma_{22}^{-1}$$

teniendo $\sigma_{(i)}$ la i -sima fila de Σ_{12} definida mediante

$$\Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}$$

Consideremos ahora la función lineal de los $\mathbf{x}^{(1)}$, $(\beta \mathbf{x}^{(2)})$. Vimos anteriormente que la covarianza entre $\mathbf{x}^{(1)} - \Sigma_{12} \Sigma_{22}^{-1} \mathbf{x}^{(2)}$, $\mathbf{x}^{(2)}$ era nula, entonces las variables $\mathbf{x}_i - \beta \mathbf{x}^{(2)}$, $\mathbf{x}^{(2)}$ eran independientes.

Trataremos de buscar una función lineal $\alpha \mathbf{x}^{(2)}$ para la que $(\mathbf{x}_i - \alpha \mathbf{x}^{(2)})$ tenga mínima variancia. Puesto que $\mathbb{E}(z^2) = \mathbb{E}(zz')$ cuando z es un escalar, la varianza sea

$$\begin{aligned} \mathbb{E}((\mathbf{x}_i - \alpha \mathbf{x}^{(2)}))^2 &= \mathbb{E}[(\mathbf{x}_i - \beta \mathbf{x}^{(2)}) + (\beta - \alpha) \mathbf{x}^{(2)}]^2 = \mathbb{E}[(\mathbf{x}_i - \beta \mathbf{x}^{(2)}) + (\beta - \alpha) \mathbf{x}^{(2)}][(\mathbf{x}_i' - \mathbf{x}^{(2)\prime}) \beta] + \\ &\quad + \mathbf{x}^{(2)\prime} (\beta - \alpha)' = \mathbb{E}[(\mathbf{x}_i - \beta \mathbf{x}^{(2)}) (\mathbf{x}_i' - \mathbf{x}^{(2)\prime}) \beta] + (\beta - \alpha) \mathbf{x}^{(2)\prime} \mathbf{x}^{(2)} (\beta - \alpha)' = \\ &= \mathbb{E}[(\mathbf{x}_i - \beta \mathbf{x}^{(2)}) (\mathbf{x}_i' - \mathbf{x}^{(2)\prime}) \beta] + (\beta - \alpha) \mathbb{E}(\mathbf{x}^{(2)\prime} \mathbf{x}^{(2)}) (\beta - \alpha)' = \\ &= \mathbb{E}(\mathbf{x}_i \mathbf{x}_i') - \beta \mathbb{E}(\mathbf{x}^{(2)} \mathbf{x}_i') - \mathbb{E}(\mathbf{x}_i \mathbf{x}^{(2)\prime}) \beta' + \beta \mathbb{E}(\mathbf{x}^{(2)\prime} \mathbf{x}^{(2)}) \beta' + (\beta - \alpha) \mathbb{E}(\mathbf{x}^{(2)\prime} \mathbf{x}^{(2)}) (\beta - \alpha)' = \\ &= \sigma_{ii} - \beta \sigma_{(i)} - \sigma_{(i)} \beta' + \beta \Sigma_{22} \beta' + (\beta - \alpha) \Sigma_{22} (\beta - \alpha)' = \\ &= \sigma_{ii} - \sigma_{(i)} \Sigma_{22}^{-1} \sigma_{(i)} - \sigma_{(i)} \Sigma_{22}^{-1} \sigma_{(i)} + \sigma_{(i)} \Sigma_{22}^{-1} \sigma_{(i)\prime} + (\beta - \alpha) \Sigma_{22} (\beta - \alpha)' = \\ &= (\sigma_{ii} - \sigma_{(i)} \Sigma_{22}^{-1} \sigma_{(i)}) + (\beta - \alpha) \Sigma_{22} (\beta - \alpha)' \end{aligned}$$

Siendo Σ_{22} s definida previamente el segundo trmino de la última linea s no negativo y alcanzará su mínimo cuando sea nulo, s decir $\alpha = \beta$. Así, la función de regresión es la función de $\mathbf{x}^{(2)}$ tal que $(\mathbf{x}_i - \alpha \mathbf{x}^{(2)})$ tiene mínima varianza.

Vamos ahora a demostrar que la máxima correlación entre \mathbf{x}_i y $\alpha \mathbf{x}^{(2)}$ se obtiene para $\alpha = \beta$. Sabemos que

$$\mathbb{E}(\mathbf{x}_i - \beta \mathbf{x}^{(2)})^2 \leq \mathbb{E}(\mathbf{x}_i - c \alpha \mathbf{x}^{(2)})^2 \quad \forall c, \forall \alpha.$$

Por tanto

$$\sigma_{ii} + \mathbb{E}(\beta \mathbf{x}^{(2)})^2 - 2 \mathbb{E}(\mathbf{x}_i \beta \mathbf{x}^{(2)}) \leq \sigma_{ii} + c^2 \mathbb{E}(\alpha \mathbf{x}^{(2)})^2 - 2c \mathbb{E}(\mathbf{x}_i \alpha \mathbf{x}^{(2)}).$$

De aquí

$$2 \frac{\mathbb{E}(\mathbf{x}_i \beta \mathbf{x}^{(2)})}{\sqrt{\sigma_{ii}} \sqrt{\mathbb{E}(\beta \mathbf{x}^{(2)})^2}} - \frac{\mathbb{E}(\beta \mathbf{x}^{(2)})^2}{\sqrt{\sigma_{ii}} \sqrt{\mathbb{E}(\beta \mathbf{x}^{(2)})^2}} \geq 2c \frac{\mathbb{E}(\mathbf{x}_i \alpha \mathbf{x}^{(2)})}{\sqrt{\sigma_{ii}} \sqrt{\mathbb{E}(\alpha \mathbf{x}^{(2)})^2}} - c^2 \frac{\mathbb{E}(\alpha \mathbf{x}^{(2)})^2}{\sqrt{\sigma_{ii}} \sqrt{\mathbb{E}(\alpha \mathbf{x}^{(2)})^2}}$$

$$\text{elegiendo } c^2 = \frac{\mathbb{E}(\beta \mathbf{x}^{(2)})^2}{\mathbb{E}(\alpha \mathbf{x}^{(2)})^2}$$

tendremos

$$\frac{\mathbb{E}(\mathbf{x}_i \beta \mathbf{x}^{(2)})}{\sqrt{\sigma_{ii}} \sqrt{\mathbb{E}(\beta \mathbf{x}^{(2)})^2}} \geq \frac{\mathbb{E}(\mathbf{x}_i \alpha \mathbf{x}^{(2)})}{\sqrt{\sigma_{ii}} \sqrt{\mathbb{E}(\alpha \mathbf{x}^{(2)})^2}}$$

Podemos ahora enunciar el siguiente teorema:

TEOREMA .- Sea \mathbf{x} un vector aleatorio normal multivariante $N(\mu, \Sigma)$. Sean $\mathbf{x}^1 = [\mathbf{x}^{(1)'} \ \mathbf{x}^{(2)'}]', \Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}$ y sea β la i -ésima fila de $\Sigma^{-1}_{22}, i=1, \dots, q$. De todas las combinaciones lineales $\alpha \mathbf{x}^{(2)}$, la combinación que minimiza la varianza de $\mathbf{x}_i - \alpha \mathbf{x}^{(2)}$, que maximiza la correlación entre \mathbf{x}_i y $\alpha \mathbf{x}^{(2)}$ es la combinación lineal $\beta \mathbf{x}^{(2)}$.

DEFINICIÓN .- La máxima correlación entre \mathbf{x}_i y la combinación lineal $\alpha \mathbf{x}^{(2)}$ se denomina coeficiente de correlación multiple entre \mathbf{x}_i y $\mathbf{x}^{(2)}$.

Se sigue que dicho coeficiente es

$$\bar{R}_{i,q+1,\dots,n} = \frac{E(\beta \mathbf{x}^{(2)} \mathbf{x}_i)}{\sqrt{\sigma_{ii}} \sqrt{E(\beta \mathbf{x}^{(2)} \mathbf{x}^{(2)'} \beta)}} = \frac{\sigma_{ii} \Sigma_{22}^{-1} \beta_{(i)'}}{\sqrt{\sigma_{ii}} \sqrt{\sigma_{ii} \Sigma_{22}^{-1} \sigma_{ii}'}} = \frac{\sqrt{\sigma_{ii} \Sigma_{22}^{-1} \sigma_{ii}'}}{\sqrt{\sigma_{ii}}}$$

Una fórmula útil es la siguiente

$$1 - \bar{R}_{i,q+1,\dots,n}^2 = \frac{\sigma_{ii} - \sigma_{ii} \Sigma_{22}^{-1} \sigma_{ii}'}{\sigma_{ii}} = \frac{|\Sigma^*|}{\sigma_{ii} |\Sigma_{22}|}$$

donde $\Sigma^* = \begin{bmatrix} \sigma_{ii} & \sigma_{ii}' \\ \sigma_{ii}' & \Sigma_{22} \end{bmatrix}$ (notar que el determinante puede obtenerse en función de los determinantes de las submatrices mediante la expresión $|\Sigma^*| = |\Sigma_{22}| \cdot |\sigma_{ii} - \sigma_{ii} \Sigma_{22}^{-1} \sigma_{ii}'|$)

Puesto que

$$\sigma_{ii,q+1,\dots,n} = \sigma_{ii} - \sigma_{ii} \Sigma_{22}^{-1} \sigma_{ii}' \quad (\text{elementos de la diagonal de } \Sigma_{22})$$

se sigue que

$$1 - \bar{R}_{i,q+1,\dots,n}^2 = \frac{\sigma_{ii,q+1,\dots,n}}{\sigma_{ii}} \rightarrow \sigma_{ii,q+1,\dots,n} = \sigma_{ii} (1 - \bar{R}_{i,q+1,\dots,n}^2)$$

lo que demuestra que cualquier varianza condicional de un componente de \mathbf{x} no puede ser mayor que la varianza. En efecto, cuanto mayor es $\bar{R}_{i,q+1,\dots,n}$, mayor es la reducción en varianza para la distribución condicional.

~~Resaltante: el coeficiente de correlación multiple es menor o igual que 1.~~
Resaltante: el coeficiente de correlación multiple es menor o igual que 1.

PROPIEDAD .- El coeficiente de correlación multiple es invariante bajo transformaciones no singulares de las variables originales.

$$\text{Supongamos} \quad Y_i = a \mathbf{x}_i + b \quad (1) \\ y^{(2)} = C \mathbf{x}^{(2)} + d$$

donde a, b son scalars, C es una matriz no singular \Rightarrow ~~no~~ b es un vector de constantes. Entonces el cuadrado del coeficiente de correlación multiple de Y_i respecto de $y^{(2)}$ es

$$\begin{aligned} \bar{R}_{i,q+1,\dots,n}^2 &= \frac{\{E(\beta^* y^{(2)} Y_i)\}^2}{\sigma_{ii} \cdot E(\beta^* y^{(2)} y^{(2)'} \beta)} = \frac{\{E(\beta^* C \mathbf{x}^{(2)} a \mathbf{x}_i)\}^2}{a^2 \sigma_{ii} E(\beta^* C \mathbf{x}^{(2)} (C \mathbf{x}^{(2)})' \beta')} = \\ &= \frac{\{a \sigma_{ii} C' (C \Sigma_{22} C)^{-1} C \sigma_{ii}'\}^2}{a^2 \sigma_{ii} \cdot (\sigma_{ii} C' (C \Sigma_{22} C)^{-1} C \sigma_{ii}')^2} = \frac{\sigma_{ii} C' (C \Sigma_{22} C)^{-1} C \sigma_{ii}'}{\sigma_{ii}} = \frac{\sigma_{ii} \Sigma_{22}^{-1} \sigma_{ii}'}{\sigma_{ii}} \end{aligned}$$

Esta propiedad implica que la misma correlación puede obtenerse indistintamente partiendo de la matriz de covarianzas o de la matriz de correlaciones. Los coeficientes de regresión de las variables transformadas (1) son

$$\gamma = a [\sigma_{ii} C'] [C \Sigma_{22} C]^{-1} = a \sigma_{ii} C' C'^{-1} \Sigma_{22}^{-1} C^{-1} = a (\sigma_{ii} \Sigma_{22}^{-1}) C^{-1} = a \beta C^{-1}$$

Si C es una matriz diagonal de factores de escala, por ejemplo los inversos de las desviaciones standard de las variables en $\Sigma^{(2)}$, el efecto de este cambio de escala consta en el producto de cada elemento de β por a/σ_i . Por ejemplo, la expresión bivariante transformaría los coeficientes en la cantidad adimensional ρ haciendo $a = \frac{1}{\sigma_1}, b = \frac{1}{\sigma_2}$.

Finalmente, si Σ y Σ_{22} tienen igual rango, q, esto significa que Σ_1 puede ser expresada exactamente como una combinación lineal de las q variables que componen $\Sigma^{(1)}$. En este caso la correlación múltiple es exactamente la unidad y β es el vector de los coeficientes de la combinación lineal. Si Σ_{22} tiene un rango menor que q, la expresión del coeficiente de correlación múltiple es indeterminada y la correlación múltiple puede ser redefinida como la máxima correlación de Σ , con una combinación lineal de un subconjunto de $\Sigma^{(2)}$ cuyo rango coincide con el de Σ_{22} .

4. FUNCIÓN CARACTÉRISTICA. MOMENTOS

Definición.- La función característica de un vector aleatorio Σ es

$$\phi(t) = E(e^{it'\Sigma}) \quad \text{para cualquier vector real } t.$$

para darle un significado a esta definición definiremos la esperanza de una función vectorial aleatoria a valores complejos, mediante

Definición.- Sea $g(x)$ una función del vector aleatorio Σ con valores complejos, que podemos escribir de la forma $g(x) = g_1(x) + i g_2(x)$, donde $g_1(x)$ y $g_2(x)$ son funciones reales. Entonces la esperanza de $g(x)$ viene dada por

$$E(g(\Sigma)) = E(g_1(\Sigma)) + i E(g_2(\Sigma))$$

En particular

$$E(e^{it'\Sigma}) = E(e^{it'_1\Sigma} + i e^{it'_2\Sigma}).$$

Es nuestro objetivo enterarse detalladamente de las propiedades de la función característica, para así encontrar algunas técnicas de gran importancia y utilidad.

Recordemos en primer lugar que el teorema de factibilidad (cuando se tienen de variables independientes), también se verifica para las funciones características, de manera que si $\Sigma' = (\Sigma^{(1)}, \Sigma^{(2)})$ siendo $\Sigma^{(1)}, \Sigma^{(2)}$ independientes entre sí

$$\phi(t) = E(e^{it'\Sigma}) = E(e^{it'^{(1)}\Sigma^{(1)}}) \cdot E(e^{it'^{(2)}\Sigma^{(2)}}) = \phi_1(t^{(1)}) \cdot \phi_2(t^{(2)}) \quad \text{en } t' = (t^{(1)}, t^{(2)}).$$

Así, si Σ esté formado por n variables independientes tendremos

$$\phi(t) = E(e^{it'\Sigma}) = \prod_{j=1}^n E(e^{it_j \Sigma_j}) = \prod_{j=1}^n \phi_j(t_j).$$

Esta propiedad nos va a permitir obtener la función característica para un vector Σ normal multivariante.

Teorema.- Sea Σ un vector aleatorio $N(\mu, \Sigma)$, entonces su función característica viene dada por

$$\phi(t) = E(e^{it'\Sigma}) = e^{it'\mu - \frac{1}{2} t'\Sigma t}, \quad \forall t, \text{vector real.}$$

Demotación.- Sabemos de la existencia de una matriz C no singular, tal que

$$C' \Sigma^{-1} C = I$$

y de aquí

$$\Sigma^{-1} = C^{-1} \cdot C^{-1} = (C C')^{-1}$$

Hagamos

$$\Sigma - \mu = C Y$$

entonces Y se distribuirá $N(0, I)$, como ya sabemos. La función característica de Y , vendrá dada por

$$\Psi(u) = E(e^{iu'Y}) = \prod_{j=1}^n E(e^{iu_j Y_j})$$

y como $Y_j \sim N(0,1)$, tendremos

$$\Psi(u) = \prod_{j=1}^n E(e^{iu_j Y_j}) = \prod_{j=1}^n e^{-\frac{1}{2}u_j^2} = e^{-\frac{1}{2}u'u}.$$

A partir de aquí

$$\phi(t) = E(e^{it'X}) = E(e^{it'(\mu + \Sigma)}) = e^{it'\mu} E(e^{it'\Sigma}) = e^{it'\mu} e^{\frac{1}{2}(t'\Sigma)(t'\Sigma)'}$$

para $t'\Sigma = u'$. Esta cadena de igualdades resulta fácilmente escribiendo los sumandos como integrales y teniendo en cuenta las reglas que rigen el cambio de variable en una integral. (~~señales difusas, cambios de variables tipo juntas de probabilidad, etc.~~). Tendremos finalmente

$$\phi(t) = e^{it'\mu - \frac{1}{2}t'\Sigma t} = e^{it'\mu - \frac{1}{2}t'\Sigma t}$$

Con el auxilio de los dos teoremas que mencionamos a continuación y del anterior resultado podemos obtener más rápidamente algunos de los anteriores resultados.

Teorema (de Levy). - Si la variable \mathbf{X} tiene una densidad $f(x)$ y una función característica $\phi(t)$, entonces

$$f(x) = \frac{1}{(2\pi)^n} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{-it'x} \phi(t) dt_1 dt_n.$$

Teorema (de la continuidad de Levy-Cramer). - Sea $\{\bar{F}_j(x)\}$ una sucesión de funciones de distribución y sea $\{\phi_j(t)\}$ la correspondiente sucesión de funciones características. Una condición necesaria y suficiente para que $\bar{F}_j(x)$ converge a una distribución $F(x)$ es que, para cualquier t , $\phi_j(t)$ converge a un límite $\phi(t)$, continua en $t=0$. Además el límite $\phi(t)$ es además la función característica de la distribución límite $F(x)$.

Obsérvese que el primero de estos teoremas dice además que las funciones de densidad y características de un vector aleatorio están en correspondencia biunívoca. Entonces:

Si $Z = D\mathbf{X}$, con $\mathbf{X} \sim N(\mu, \Sigma)$, la función característica de Z tendrá por expresión

$$\begin{aligned} \phi(t) &= E(e^{it'Z}) = E(e^{it'D\mathbf{X}}) = E(e^{i(Dt)' \mu - \frac{1}{2}(D't)' \Sigma (D't)}) = \\ &= e^{it'(\mu) - \frac{1}{2}t'(\Sigma D)t} \end{aligned}$$

aplicando el teorema de Levy llegamos a la conclusión de que Z es normal con media $D\mu$ y matriz de covarianzas $D\Sigma D'$.

Análogamente al uso de las funciones características y sus propiedades nos permite demostrar el siguiente

Teorema. - Si alguna combinación lineal de los componentes de un vector \mathbf{X} redistribuye normalmente, entonces \mathbf{Y} se distribuye normalmente.

Demuestra. - Supongamos la combinación lineal $Z = u'Y$ que se distribuye normalmente, tendremos que su función característica tendrá forma por

$$E(e^{it'Z}) = E(e^{it'u'Y}) = e^{it'u'\mu - \frac{1}{2}t'u'\Sigma u}$$

siendo μ y Σ la media y matriz de covarianzas de \mathbf{Y} . Si hacemos ahora $t=1$, tendremos que

$$E(e^{iu'Y}) = e^{iu'\mu - \frac{1}{2}u'\Sigma u}, \text{ por tanto } \mathbf{Y} \text{ se distribuirá normalmente.}$$

Es muy importante insistir en el hecho de que tanto de los momentos μ_j como las combinaciones lineales de los componentes de Σ . Puede verse un ejemplo en Anderson, págs. 37, 38.

2 (9)

Momentos de un vector aleatorio normal

Los momentos de $\Sigma_{11}, \dots, \Sigma_{pp}$ en una distribución conjunta normal pueden obtenerse a partir de la función caractéristica. Así sea:

$$E(\bar{X}_j) = \frac{1}{i} \left. \frac{\partial \phi}{\partial t_j} \right|_{t=0} = \frac{1}{i} \left. \left(- \sum_k \delta_{jk} t_k + i \mu_j \right) \phi(t) \right|_{t=0} = \mu_j$$

$$\begin{aligned} E(\bar{X}_n \bar{X}_j) &= \frac{1}{i^2} \left. \frac{\partial^2 \phi}{\partial t_n \partial t_j} \right|_{t=0} = \frac{1}{i^2} \left. \left\{ \left(- \sum_k \delta_{nk} t_k + i \mu_n \right) \left(- \sum_k \delta_{kj} t_k + i \mu_j \right) - \delta_{nj} \right\} \phi(t) \right|_{t=0} = \\ &= \delta_{nj} - \mu_n \mu_j \end{aligned}$$

y así sucesivamente.

5. MUESTRAS DE UNA NORMAL MULTIVARIANTE

En todo momento procede hemos estudiado las propiedades de una distribución normal multivariante como si los valores de sus parámetros fueran conocidos y estuvieran bajo control. Esta situación no es cierta generalmente. Desgraciadamente la biología y ciencias del comportamiento no son así generalmente y lo que pretendemos en este apartado es considerar métodos que permitan estimar los diferentes parámetros de la normal multivariante a partir de muestras relativamente pequeñas y estudiar, después, las propiedades muestrales de estos estimadores.

Ante de entrar en detalle acerca de la obtención de los estimadores insistir en la impresión necesidad de que la aleatoriedad de la muestra considerada sea cierta si queremos que nuestras observaciones tengan alguna validez. Es decir, se trata de que las unidades muestrales formen ríos formadas independientemente unas de otras de una población homogénea. Estas unidades muestrales no pueden tener características comunes o rasgos que pudieran indicar alguna independencia entre ellas. Por ejemplo, una investigación de los niveles medios de cuatro componentes bioquímicos en el cerebro de cierta raza de ratas no puede estar basada en muestras extraídas de una sola camada de ratas, por ejemplo que estén rean, sino en muestras extraídas aleatoriamente de ratas de la ciudad París. De la misma manera, obtenemos estimaciones basadas en las respuestas diarias de un pequeño número de pacientes hospitalarios estudiados durante varias semanas. La misma forma que elementos de una misma camada de ratas tienen probablemente rasgos biológicos y genéticos comunes, parece razonable pensar que ante condición aparente del paciente tiene rasgos variando tan ligeramente que tienen las contribuciones de días sucesivos altamente dependientes. Además, variaciones importantes en el comportamiento de una persona en la sala del hospital donde se encuentran los enfermos examinados indicaría probablemente cambios en los otros sujetos del estudio.

Estimadores máximos-razonables del vector media y de la matriz de covarianzas

Fataremos de obtener los estimadores máximos-razonables de μ, Σ a partir de una muestra de N observaciones procedentes de una población normal p -variente cuyos parámetros son precisamente μ, Σ .

La elección, precisamente, de este tipo de estimadores se debió a que tienen ellos o algunas simples transformaciones de los mismos, propiedades óptimas de los estimadores. En el caso particular que ahora nos ocupa, los estimadores son asintóticamente eficientes.

Supongamos que nuestra muestra de tamaño N esté constituida por los vectores p -variantes $X_1, \dots, X_N, N > p$. La función de verosimilitud de la muestra viene dada por

$$L = \frac{1}{(2\pi)^{\frac{pN}{2}} |\Sigma|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x}_\alpha - \boldsymbol{\mu}) \right]$$

Como el exponente aparece en términos de $\boldsymbol{\Sigma}^{-1}$ obtendremos primero los estimados de $\boldsymbol{\mu}$, $\boldsymbol{\Sigma}^{-1} = \boldsymbol{\Psi}$. Recordemos que en la función L , las variables son $\boldsymbol{\mu}$ y $\boldsymbol{\Sigma}$, mientras que \mathbf{x}_α son otras variables y por tanto perfectamente conocidas.

Para maximizar L , lo haremos a través de su log, por cuanto el log es una función creciente y el máximo coincidirá. Así pues

$$\log L = -\frac{1}{2} pN \log(2\pi) + \frac{1}{2} \log |\boldsymbol{\Psi}| - \frac{1}{2} \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \boldsymbol{\mu})' \boldsymbol{\Psi} (\mathbf{x}_\alpha - \boldsymbol{\mu}).$$

Definamos la media muestral como

$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{\alpha=1}^N \mathbf{x}_\alpha = \begin{bmatrix} \frac{1}{N} \sum_{\alpha=1}^N x_{1\alpha} \\ \vdots \\ \frac{1}{N} \sum_{\alpha=1}^N x_{p\alpha} \end{bmatrix} = \begin{bmatrix} \bar{x}_1 \\ \vdots \\ \bar{x}_p \end{bmatrix}$$

y la matriz de los sumas de cuadrados y productos análogos de las desviaciones respecto a la media

$$A = \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' = \left[\sum_{\alpha=1}^N (\mathbf{x}_{i\alpha} - \bar{x}_i)(\mathbf{x}_{j\alpha} - \bar{x}_j) \right] \quad i, j = 1, \dots, p$$

Queremos obtener de dar otra expresión a $\log L$, para ello recordaremos algunas propiedades que tenemos acerca de la matrix.

Teorema. - Sean $\mathbf{x}_1, \dots, \mathbf{x}_N$ N vectores y sea $\bar{\mathbf{x}}$ la media antis definida. Entonces para cualquier vector \mathbf{b}

$$\sum_{\alpha=1}^N (\mathbf{x}_\alpha - \mathbf{b})(\mathbf{x}_\alpha - \mathbf{b})' = \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' + N(\bar{\mathbf{x}} - \mathbf{b})(\bar{\mathbf{x}} - \mathbf{b})'$$

Demostración.-

$$\begin{aligned} \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \mathbf{b})(\mathbf{x}_\alpha - \mathbf{b})' &= \sum_{\alpha=1}^N [(\mathbf{x}_\alpha - \bar{\mathbf{x}}) + (\bar{\mathbf{x}} - \mathbf{b})][(\mathbf{x}_\alpha - \bar{\mathbf{x}}) + (\bar{\mathbf{x}} - \mathbf{b})]' = \\ &= \sum_{\alpha=1}^N [(\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' + (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\bar{\mathbf{x}} - \mathbf{b})' + (\bar{\mathbf{x}} - \mathbf{b})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' + (\bar{\mathbf{x}} - \mathbf{b})(\bar{\mathbf{x}} - \mathbf{b})'] = \\ &= \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' + \left[\sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}}) \right] (\bar{\mathbf{x}} - \mathbf{b})' + (\bar{\mathbf{x}} - \mathbf{b}) \left[\sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})' \right] + N(\bar{\mathbf{x}} - \mathbf{b})(\bar{\mathbf{x}} - \mathbf{b})' = \\ &= \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' + N(\bar{\mathbf{x}} - \mathbf{b})(\bar{\mathbf{x}} - \mathbf{b})' \end{aligned}$$

$$\text{Pues } \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}}) = N\bar{\mathbf{x}} - N\bar{\mathbf{x}} = 0.$$

Si hacemos $\mathbf{b} = \boldsymbol{\mu}$, tendremos

$$\sum_{\alpha=1}^N (\mathbf{x}_\alpha - \boldsymbol{\mu})(\mathbf{x}_\alpha - \boldsymbol{\mu})' = \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})' + N(\bar{\mathbf{x}} - \boldsymbol{\mu})(\bar{\mathbf{x}} - \boldsymbol{\mu})' = A + N(\bar{\mathbf{x}} - \boldsymbol{\mu})(\bar{\mathbf{x}} - \boldsymbol{\mu})'.$$

Por otra parte haciendo uso de la propiedad de la traza de una matriz que dice: $\text{tr}(CD) = \text{tr}(DC) = \sum c_{ij}d_{ji}$, tenemos

$$\begin{aligned} \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \boldsymbol{\mu})' \boldsymbol{\Psi} (\mathbf{x}_\alpha - \boldsymbol{\mu}) &= \text{tr} \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \boldsymbol{\mu})' \boldsymbol{\Psi} (\mathbf{x}_\alpha - \boldsymbol{\mu}) = \text{tr} \sum_{\alpha=1}^N \boldsymbol{\Psi} (\mathbf{x}_\alpha - \boldsymbol{\mu})(\mathbf{x}_\alpha - \boldsymbol{\mu})' = \text{tr} \sum_{\alpha=1}^N \boldsymbol{\Psi} [A + N(\bar{\mathbf{x}} - \boldsymbol{\mu})(\bar{\mathbf{x}} - \boldsymbol{\mu})]' = \\ &= \text{tr} \boldsymbol{\Psi} A + \text{tr} \boldsymbol{\Psi} N(\bar{\mathbf{x}} - \boldsymbol{\mu})(\bar{\mathbf{x}} - \boldsymbol{\mu})' = \text{tr} \boldsymbol{\Psi} A + N(\bar{\mathbf{x}} - \boldsymbol{\mu})' \boldsymbol{\Psi} (\bar{\mathbf{x}} - \boldsymbol{\mu}) \end{aligned}$$

Podemos entonces escribir el $\log L$ de la siguiente manera

$$\log L = -\frac{1}{2} p \log(2\pi) + \frac{1}{2} N \log |D| - \frac{1}{2} \text{tr} A - \frac{1}{2} N(\bar{x} - \mu)^T A (\bar{x} - \mu)$$

La matriz A es definida positiva, por tanto $N(\bar{x} - \mu)^T A (\bar{x} - \mu) > 0$, $A(\bar{x} - \mu) \neq 0$, es decir que no es nula cuando $\bar{x} - \mu = 0$, o sea $\mu = \bar{x}$. Para maximizar el segundo y tercer término de la expresión anterior tenemos presente el siguiente resultado

LEMMA. - Sea

$$f(C) = \frac{1}{2} N \log |C| - \frac{1}{2} \sum_{ij=1}^p C_{ij} d_{ij}$$

donde $C = [c_{ij}]$ es definida positiva, y donde $D = [d_{ij}]$ es definida positiva. Entonces el máximo de $f(C)$ se alcanza para $C = ND^{-1}$, este máximo es

$$f(ND^{-1}) = \frac{1}{2} p N \log N - \frac{1}{2} N \log |D| - \frac{1}{2} p N$$

Demarcación. - Observese que $f(C)$ tiende a $-\infty$ cuando C se approxima a una matriz singular. Formalmente se demuestra (verse Anderson pag. 47) que si entre los mismos cuando algunos o algunos elementos de C se aproximan a 0 y/o $+\infty$, los máximos de $f(C)$ rendirían más dados igualando a cero las derivadas respectivas a los elementos de C . Tenemos

$$\frac{\partial f}{\partial c_{kk}} = \frac{1}{2} \frac{N}{|C|} \frac{\partial |C|}{\partial c_{kk}} - \frac{1}{2} d_{kk} = \frac{1}{2} N \frac{G_{kk}}{|C|} - \frac{1}{2} d_{kk}$$

donde G_{kk} es el cofactor de c_{kk} en C . Para $k \neq l$

$$\frac{\partial f}{\partial c_{kl}} = \frac{1}{2} \frac{N}{|C|} \frac{\partial |C|}{\partial c_{kl}} - \frac{1}{2} (d_{kk} + d_{ll})$$

teniendo en cuenta la simetría de C y de D , tenemos

$$\frac{\partial f}{\partial c_{kl}} = N \frac{G_{kk}}{|C|} - d_{kk}$$

donde G_{kk} es el cofactor de c_{kk} en C . Igualando a cero estas parciales y teniendo en cuenta que $G_{kk}/|C|$ es el k, k -ésimo elemento de C^{-1} , tenemos $NC^{-1}=D$, y de aquí $C=ND^{-1}$. El correspondiente valor máximo para $f(ND^{-1})$ es

$$f(ND^{-1}) = \frac{1}{2} N \log |ND^{-1}| - \frac{1}{2} \text{tr } ND^{-1} D = \frac{1}{2} N \log N^p |D^{-1}| - \frac{1}{2} N \text{tr } D =$$

$$= \frac{1}{2} p N \log N - \frac{1}{2} N \log |D| - \frac{1}{2} N p$$

Aplicando este lema a la función $\log L$ podemos maximizar para $\Psi = NA^{-1} = \left(\frac{1}{N} A\right)^{-1}$. Supongamos que A no es singular para que tenga sentido lo visto (no tiene sentido que esto suene con probabilidad 1). De nuevo los estimados máximos relativos de μ y Ψ son $\hat{\mu} = \bar{x}$ y $\hat{\Psi} = NA^{-1}$. Para encontrar ahora el estimador de Σ necesitamos el siguiente lema y su contrario.

LEMMA. - Sea $f(\theta)$ una función real definida en un conjunto S y sea ϕ una función real a valores reales, con una inversa de ciertas características, de S a algún otro conjunto S^* ; es decir, para cada $\theta \in S$ \exists un único $\theta^* \in S^*$ e inversamente para cada $\theta^* \in S^*$. Sea

$$g(\theta^*) = f[\phi'(\theta^*)].$$

Entonces si $f(\theta)$ alcanza su máximo en $\theta = \theta_0$, $g(\theta^*)$ alcanza su máximo en $\theta^* = \theta_0^* = \phi(\theta_0)$. Si el máximo de $f(\theta)$ es único en θ_0 , igual sucede en el máximo de $g(\theta^*)$ en θ_0^* .

Demonstración - Por hipótesis

$$f(\theta_0) \geq f(\theta), \quad \forall \theta \in S$$

Bienvenido para $\forall \theta^* \in S^*$, tenemos

$$g(\theta^*) = f[\phi'(\theta^*)] = f(\theta) \leq f(\theta_0) = g[\phi(\theta_0)] = g(\theta_0)$$

Resulta que $g(\theta^*)$ alcanza su máximo en θ^* . Si el máximo de $f(\theta)$ en θ_0 es único, la desigualdad anterior es estricta para $\theta \neq \theta_0$ y por tanto el máximo para $g(\theta^*)$ es único.

Tenemos el siguiente corolario.

Corolario - Si sobre la base de una muestra dada $\hat{\theta}_1, \dots, \hat{\theta}_m$ son los estimadores máximos verosimiles de los parámetros $\theta_1, \dots, \theta_m$ de una distribución, entonces $\phi_1(\hat{\theta}_1, \dots, \hat{\theta}_m), \dots, \phi_m(\hat{\theta}_1, \dots, \hat{\theta}_m)$ son los estimadores máximos verosimiles de $\phi_1(\theta_1, \dots, \theta_m), \dots, \phi_m(\theta_1, \dots, \theta_m)$ (las transformaciones de $\theta_1, \dots, \theta_m$ a ϕ_1, \dots, ϕ_m son a uno). Si los estimadores de $\theta_1, \dots, \theta_m$ son únicos, esto también ocurre en los ϕ_1, \dots, ϕ_m .

Aplicando el corolario a nuestra situación podemos afirmar que el estimador máximo verosímil de Σ viene dado por $\hat{\Sigma} = \Phi^{-1} = (1/N) A$. Razonamiento:

Teorema - Si x_1, \dots, x_N constituye una muestra de una $N(\mu, \Sigma)$ ($p < N$), los estimadores máximos verosimiles de μ y Σ son $\hat{\mu} = \bar{x} = (1/N) \sum_{\alpha} x_{\alpha}$ y $\hat{\Sigma} = (1/N) \sum_{\alpha} (x_{\alpha} - \bar{x})(x_{\alpha} - \bar{x})'$.

Corolario - Si x_1, \dots, x_N constituye una muestra de una $N(\mu, \Sigma)$, donde $\theta_{ij} = \theta_i \delta_{ij} \theta_{jj}$ ($\theta_{ii}=1$), el estimador máximo verosímil de μ es $\bar{x} = (1/N) \sum_{\alpha} x_{\alpha}$, los estimadores máximos verosimiles de $\theta_{ii}^2 = \hat{\theta}_{ii}^2 = (1/N) \sum_{\alpha} (x_{i\alpha} - \bar{x}_i)^2 = (1/N) (\sum_{\alpha} x_{i\alpha}^2 - N\bar{x}_i^2)$, donde $x_{i\alpha}$ es la i -ésima componente de x_{α} y \bar{x}_i es la i -ésima componente de \bar{x} . (el estimador máximo-verosímil de θ_{ij} es

$$\hat{\theta}_{ij} = \frac{\sum_{\alpha} (x_{i\alpha} - \bar{x}_i)(x_{j\alpha} - \bar{x}_j)}{\sqrt{\sum_{\alpha} (x_{i\alpha} - \bar{x}_i)^2 \cdot \sum_{\alpha} (x_{j\alpha} - \bar{x}_j)^2}}$$

Demonstración - El conjunto de parámetros $\mu_i = \mu_i, \theta_{ii}^2 = \theta_{ii}^2$ y $\theta_{ij} = \frac{\theta_{ij}}{\sqrt{\theta_{ii}\theta_{jj}}}$ son transformaciones uno a uno del conjunto de parámetros μ_i, θ_{ij} . Aplicando el corolario anterior los estimadores máximos verosimiles son las correspondientes transformadas.

Vamos a formalizar este apartado de los estimadores máximo verosimil de μ, Σ dando una interpretación geométrica de algunos de los elementos que aparecen en estos estimadores.

Una conveniente interpretación de la muestra desde un punto de vista geométrico, viene en términos de las filas de la matriz de datos $\mathbf{X} = (x_1, \dots, x_N)$, a saber

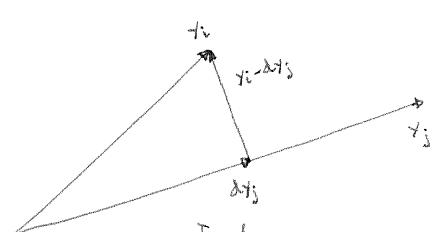


Fig. 1

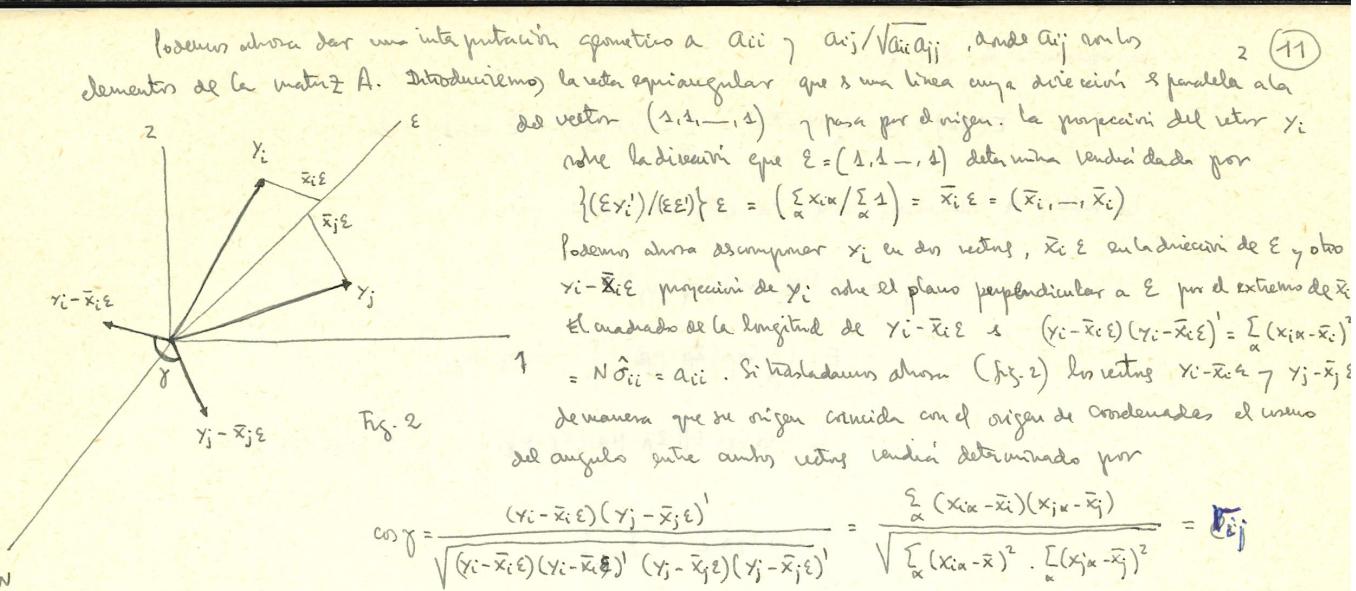
$$\mathbf{X} = \begin{bmatrix} x_{11} & \dots & x_{1N} \\ \vdots & \ddots & \vdots \\ x_{p1} & \dots & x_{pN} \end{bmatrix} = \begin{bmatrix} y_1 \\ \vdots \\ y_p \end{bmatrix}$$

El vector y_i puede ser considerado como un elemento en el espacio euclídeo N -dimensional, más concretamente como el extremo de un vector en \mathbb{R}^N , cuyo origen coincide en el origen de coordenadas.

Comprobemos en primer lugar que el seno del ángulo entre y_i e y_j es $|y_i y_j'| / \sqrt{y_i y_i' y_j y_j'}$

En efecto, elegiremos un vector d de tal forma que $d y_j$ e $y_i - d y_j$ sean ortogonales. Entonces $d y_j (y_i - d y_j)' = 0$ y de aquí $d(y_j y_i' - d y_j y_i') = 0 \rightarrow d = y_j y_i' / y_j y_j'$. Si descomponemos ahora y_i en $d y_j$ e $y_i - d y_j$ (ver fig. 1) tenemos que el valor absoluto del seno del ángulo que forman y_i e y_j vendrá dado por el cociente entre la longitud de $d y_j$ y la longitud de y_i , es decir

$$\sqrt{\frac{(d y_j)(d y_j)'}{y_i y_i'}} = \sqrt{\frac{d y_j y_j' d}{y_i y_i'}} = \sqrt{\frac{(y_i y_j')(y_j y_j')(y_i y_i')}{(y_j y_j')(y_i y_i')(y_j y_j')}} = \frac{|y_i y_j'|}{\sqrt{(y_i y_i')(y_j y_j')}}$$



6.- DISTRIBUCIÓN DEL VECTOR MEDIA MUESTRAL. INFERNENIAS ACERCA DE μ CUANDO Σ ES CÓNDIDA

La distribución conjunta de μ y Σ .

Recordemos que en el caso univariante la media muestral y la variancia muestral se distribuyen independiente-mente una de otra y además, la media, en particular, se distribuye normalmente, cuando la población de origen es normal. El resultado similar puede demostrarse para el caso multivariante, previamente a ello haremos al conjunto de los observaciones una transformación.

TEOREMA .- Supongamos que x_{11}, \dots, x_{1N} son independientes, con $x_{1\alpha}$ distribuidos $N(\mu_{1\alpha}, \Sigma)$. Sea $G = (C_{\alpha\beta})$ una matriz ortogonal. Entonces $y_{1\alpha} = \sum_{\beta=1}^N C_{\alpha\beta} x_{1\beta}$ se distribuye según una $N(\mu_{1\alpha}, \Sigma)$, con $\nu_{1\alpha} = \sum_{\beta=1}^N C_{\alpha\beta} \mu_{1\beta}$ y y_{11}, \dots, y_{1N} son independientes.

Demotación .- El conjunto de los rectas $\{y_{1\alpha}\}$ tiene una distribución conjunta normal puesto que el conjunto de todos sus componentes es un conjunto de combinaciones lineales de las componentes de $\{x_{1\alpha}\}$ que tienen una distribución conjunta normal. De efecto, observe que

$$f(x_1, x_2, \dots, x_N) = \frac{1}{(2\pi)^{\frac{NP}{2}} |\Sigma|^{\frac{N}{2}}} \exp \left\{ -\frac{1}{2} \sum_{\alpha} (x_{\alpha} - \mu_{\alpha})^T \Sigma^{-1} (x_{\alpha} - \mu_{\alpha}) \right\}$$

que puede escribirse de la forma

$$f(x_{11} x_{12} - x_{1P}, x_{21} - x_{2P}, \dots, x_{N1} - x_{NP}) = \frac{1}{(2\pi)^{\frac{NP}{2}} |\Sigma|^{\frac{N}{2}}} \exp \left\{ -\frac{1}{2} ((x_1 - \mu_1), \dots, (x_N - \mu_N))^T \Sigma^{*-1} ((x_1 - \mu_1), \dots, (x_N - \mu_N)) \right\}$$

donde Σ^* es una matriz de submatrices de la forma

$$\Sigma^* = \begin{bmatrix} \Sigma & 0 & \cdots & 0 \\ 0 & \Sigma & \cdots & 0 \\ \vdots & & \ddots & \\ 0 & 0 & \cdots & \Sigma \end{bmatrix} \quad \text{de dimensión } Np \times Np$$

y su determinante vale $|\Sigma^*| = |\Sigma|^N$.

El paso de los vectores $x_{1\alpha}$ a los $y_{1\alpha}$ puede llevase a cabo mediante una transformación del tipo

$$\begin{bmatrix} y_{11} \\ y_{12} \\ \vdots \\ y_{1P} \\ \vdots \\ y_{1Np} \end{bmatrix} = C^* \begin{bmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{N1} \\ \vdots \\ x_{NP} \end{bmatrix} \quad \text{con } C^* = \begin{bmatrix} G & 0 & \cdots & 0 \\ 0 & G & \cdots & 0 \\ \vdots & & \ddots & \\ 0 & 0 & \cdots & G \end{bmatrix}$$

la esperanza de γ_α es

$$E(\gamma_\alpha) = E\left(\sum_\beta c_{\alpha\beta} \bar{x}_\beta\right) = \sum_\beta c_{\alpha\beta} E(\bar{x}_\beta) = \sum_\beta c_{\alpha\beta} \mu_\beta = v_\alpha.$$

la matriz de covarianzas entre γ_α e γ_γ viene dada por

$$\begin{aligned}\text{Cov}(\gamma_\alpha, \gamma_\gamma) &= E[(\gamma_\alpha - v_\alpha)(\gamma_\gamma - v_\gamma)'] = \\ &= E\left[\left(\sum_\beta c_{\alpha\beta} (\bar{x}_\beta - \mu_\beta)\right)\left(\sum_\gamma c_{\gamma\beta} (\bar{x}_\beta - \mu_\beta)\right)'\right] = \\ &= \sum_{\beta,\gamma} c_{\alpha\beta} c_{\gamma\beta} E[(\bar{x}_\beta - \mu_\beta)(\bar{x}_\gamma - \mu_\gamma)'] = \sum_{\beta,\gamma} c_{\alpha\beta} c_{\gamma\beta} \delta_{\beta\gamma} \Sigma = \\ &= \sum_\beta c_{\alpha\beta} c_{\gamma\beta} \Sigma = \delta_{\alpha\gamma} \Sigma\end{aligned}$$

donde $\delta_{\alpha\gamma}$ es la delta de Kronecker ($= 1$ si $\alpha=\gamma$ e $= 0$ si $\alpha \neq \gamma$). Este resultado muestra que γ_α es independiente de γ_γ , que γ_α tiene matriz de covarianzas Σ .

LEMMA. — Si $G = [c_{\alpha\beta}]$ es ortogonal, entonces $\sum_{\alpha=1}^N \bar{x}_\alpha \bar{x}_\alpha' = \sum_{\alpha=1}^N \gamma_\alpha \gamma_\alpha'$, donde $\gamma_\alpha = \sum_\beta c_{\alpha\beta} \bar{x}_\beta$.

Demonstración. —

$$\sum_{\alpha} \gamma_\alpha \gamma_\alpha' = \sum_{\alpha} \left(\sum_{\beta} c_{\alpha\beta} \bar{x}_\beta \right) \left(\sum_{\gamma} c_{\gamma\beta} \bar{x}_\gamma \right)' = \sum_{\beta} \left(\sum_{\alpha} c_{\alpha\beta} c_{\gamma\beta} \right) \bar{x}_\beta \bar{x}_\beta' = \sum_{\beta} \delta_{\beta\gamma} \bar{x}_\beta \bar{x}_\beta' = \sum_{\beta} \bar{x}_\beta \bar{x}_\beta'.$$

Sean ahora $\bar{x}_1, \dots, \bar{x}_N$ independientes, cada uno de ellos distribuidos de acuerdo con una $N(\mu, \Sigma)$. Entonces existe una matriz ortogonal $B = [b_{\alpha\beta}]$ cuya última fila es

$$(1/\sqrt{N}, \dots, 1/\sqrt{N}).$$

Esta transformación es una rotación en el espacio N dimensional en la que la linea equiangular descripta anteriormente se hace coincidir con el N -ésimo eje de coordenadas. Sea A la matriz de la suma de los cuadrados de los desviaciones repetitiva de la media muestral y los productos mixtos de las mismas, a decir $A = N \bar{\Sigma}$, y sea

$$\bar{z}_\alpha = \sum_\beta b_{\alpha\beta} \bar{x}_\beta.$$

Entonces

$$\bar{z}_N = \sum_\beta b_{N\beta} \bar{x}_\beta = \sum_\beta \frac{1}{\sqrt{N}} \bar{x}_\beta = \sqrt{N} \bar{x}$$

Por el lema anterior tenemos:

$$A = \sum_{\alpha=1}^N \bar{x}_\alpha \bar{x}_\alpha' - N \bar{x} \bar{x}' = \sum_{\alpha=1}^N \bar{z}_\alpha \bar{z}_\alpha' - \bar{z}_N \bar{z}_N' = \sum_{\alpha=1}^{N-1} \bar{z}_\alpha \bar{z}_\alpha'$$

Puesto que \bar{z}_N es independiente de $\bar{z}_1, \dots, \bar{z}_{N-1}$, \bar{x} será independiente de A . Por otra parte

$$E[\bar{z}_N] = \sum_\beta b_{N\beta} E(\bar{x}_\beta) = \sum_\beta \frac{1}{\sqrt{N}} \mu_\beta = \sum_\beta \frac{1}{\sqrt{N}} \mu = \sqrt{N} \mu,$$

con lo que \bar{z}_N se distribuye $N(\sqrt{N}\mu, \Sigma)$ y por tanto $\bar{x} = \frac{1}{\sqrt{N}} \bar{z}_N$ es $N(\mu, \frac{1}{N} \Sigma)$.

Además

$$E(\bar{z}_\alpha) = \sum_\beta b_{\alpha\beta} E(\bar{x}_\beta) = \sum_\beta b_{\alpha\beta} \mu = \sum_\beta b_{\alpha\beta} b_{N\beta} \sqrt{N} \mu = 0, \text{ para } \alpha \neq N.$$

Podemos resumir todos estos resultados en el siguiente teorema



TEOREMA - La media muestral de una muestra de tamaño N de una población $N(\mu, \Sigma)$ se distribuye de acuerdo con una $N(\mu, (\frac{1}{N})\Sigma)$ e independientemente de $\hat{\Sigma}$, estimador máximo verosímil de Σ . $N\hat{\Sigma}$ se distribuye igual que $\sum_{\alpha=1}^{N-1} Z_\alpha Z_\alpha'$ donde Z_α se distribuye $N(0, \Sigma)$ e independientemente de Z_β ($\alpha \neq \beta$).

Observemos por otra parte que

$$E(\hat{\Sigma}) = \frac{1}{N} \sum_{\alpha=1}^{N-1} E(Z_\alpha Z_\alpha') = \frac{N-1}{N} \Sigma$$

Resulta pues que $\hat{\Sigma}$ es un estimador sesgado de Σ . Lo podemos corregir en un estimador desviado definiendo

$$S = \frac{1}{N-1} A = \frac{1}{N-1} \sum_{\alpha=1}^N (x_\alpha - \bar{x})(x_\alpha - \bar{x})'$$

matriz conocida como la matriz de covarianzas muestral. Sus elementos ^{diagonal} en los estimadores más juntas habrá de las covarianzas de los componentes de Σ .

Inferencia acerca de μ cuando Σ es conocida

Un problema estadístico de considerable importancia es el de contrastar la hipótesis de que el vector media de una distribución normal tiene cierto valor, que problema directamente relacionado con el de dar una región de confianza para dicho vector media. Tenemos a estudiar este problema bajo el supuesto de conocer la matriz de covarianzas Σ . Más adelante consideraremos otros problemas para el caso en que resulte desconocida Σ .

Recordemos que en el caso univariante y bajo plantearonlos anteriores, los tests intervalos de confianza para la media se basan en el hecho de que la diferencia entre la media muestral y la poblacional se distribuye normalmente con media 0 y varianza conocida. En el caso multivariante en cambio, también sobre esta diferencia se distribuye normalmente con vector media nula y matriz de covarianzas conocida. Podríamos elegir límites para cada componente sobre la base de esta distribución, pero este procedimiento tiene la desventaja de que la elección de límite es arbitraria y en el caso de tests ~~que~~ conducen a ~~los~~ tests que pueden ser muy pobres frente a algunas alternativas, lo conlleva la dificultad de calcular los referidos límites por cuenta propia de tablas para la matriz bivariante. El procedimiento que tenemos a disponer es mucho encaja a la obtención de resultados y además puede darse justificaciones teóricas e intuitivas general.

El procedimiento se basa en el siguiente teorema:

TEOREMA - Si las m -componentes de un vector Y se distribuyen de acuerdo con una $N(0, I)$ (no singulares), entonces $Y' T^{-1} Y$ se distribuye según una χ^2 con m grados de libertad.

Demuestremos - Sea C una matriz no singular tal que $C T C' = I$ y definimos $Z = CY$. Entonces Z se distribuye normalmente con media 0 y matriz de covarianzas $E(ZZ') = E(CYY'C) = CTC' = I$. Entonces $Y' T^{-1} Y = Z'(C')^{-1} T^{-1} C' Z = Z'(CTC')^{-1} Z = Z'Z$ que es la suma de los cuadrados de las componentes de Z . Como cada componente es $N(0, 1)$ e independiente de las otras, $Z'Z = Y' T^{-1} Y$ es una χ^2 con m grados de libertad.

Ahora bien, $\sqrt{N}(\bar{X} - \mu)$ se distribuye $N(0, \Sigma)$, aplicando el teorema

$$N(\bar{X} - \mu)' \Sigma^{-1} (\bar{X} - \mu)$$

será una χ^2 con p grados de libertad. Este método es fundamental para determinar regiones de confianza para μ .

Ser $\chi_p^2(\alpha)$ el número tal que

$$P(X_p^2 \geq \chi_p^2(\alpha)) = \alpha.$$

Entonces

$$P(N(\bar{X} - \mu)' \Sigma^{-1} (\bar{X} - \mu) \geq \chi_p^2(\alpha)) = \alpha$$

Para contrastar la hipótesis $H_0: \mu = \mu_0$, utilizaremos como región crítica (\rightarrow de rechazo)

$$N(\bar{x} - \mu_0)^T \Sigma^{-1} (\bar{x} - \mu_0) \geq \chi_p^2(\alpha)$$

Intuitivamente podemos decir que la probabilidad de rechazar μ_0 sea mayor que α si μ_0 es muy diferente de μ . Puesto que en el espacio de los \bar{x} , la expresión anterior representa una hipérfeliz centrada en μ_0 y cuando μ esté alejado de μ_0 la densidad de \bar{x} se concentrará en un punto fuera de la mitad elipse, teniendo más difícil encontrar valores de \bar{x} cercanos a μ_0 .

Una demostración análoga a la del teorema anterior nos llevaría a demostrar que $N(\bar{x} - \mu_0)^T \Sigma^{-1} (\bar{x} - \mu_0)$ se distribuye como una χ^2 centrada con p g.l. y parámetros de no centralización $N(\mu - \mu_0)^T \Sigma^{-1} (\mu - \mu_0)$ cuando \bar{x} es la media de una muestra de tamaño N de una $N(\mu, \Sigma)$. La primera demostración se teórica anterior fue hecha por Pearson en 1900.

Consideremos ahora la siguiente afirmación basada sobre la base de una muestra con media \bar{x} : "La media de la distribución satisface

$$N(\bar{x} - \mu^*)^T \Sigma^{-1} (\bar{x} - \mu^*) \leq \chi_p^2(\alpha)$$

considerada como una desigualdad sobre μ^* . De acuerdo con lo anterior la probabilidad de que extraigamos una muestra tal que sea cierta la afirmación es $1 - \alpha$, puesto que el suceso $\{N(\bar{x} - \mu^*)^T \Sigma^{-1} (\bar{x} - \mu^*) \geq \chi_p^2(\alpha)\}$ es equivalente a negar la afirmación. Así, el conjunto de todos μ^* que satisfacen la última desigualdad son los que constituyen una región de confianza para μ con un nivel de confianza de $1 - \alpha$.

En un espacio p -dimensional de \bar{x} , $N(\bar{x} - \mu_0)^T \Sigma^{-1} (\bar{x} - \mu_0) \geq \chi_p^2(\alpha)$ es la superficie y el exterior de un dipoloide centrado en μ_0 , la forma del elipsoide depende de Σ^{-1} y el tamaño de $(\sqrt{N}) \chi_p^2(\alpha)$ para Σ^{-1} dado. En el espacio p -dimensional de μ^* , $N(\bar{x} - \mu^*)^T \Sigma^{-1} (\bar{x} - \mu^*) \leq \chi_p^2(\alpha)$ es la superficie y el interior de un elipsoide centrado en \bar{x} . Si $\Sigma^{-1} = I$, la fracción $\{N(\bar{x} - \mu^*)^T \Sigma^{-1} (\bar{x} - \mu^*) \geq \chi_p^2(\alpha)\} = \alpha$, significando que la probabilidad de que la distancia entre \bar{x} y μ^* sea mayor que $[(\sqrt{N}) \chi_p^2(\alpha)]^{1/2}$ es igual a α .

TEOREMA - Si \bar{x} es la media de una muestra de N elementos extraída de una $N(\mu, \Sigma)$ y si Σ es conocida, entonces $N(\bar{x} - \mu_0)^T \Sigma^{-1} (\bar{x} - \mu_0) \geq \chi_p^2(\alpha)$ da una región crítica de tamaño α para contrastar la hipótesis $H_0: \mu = \mu_0$ y $N(\bar{x} - \mu^*)^T \Sigma^{-1} (\bar{x} - \mu^*) \leq \chi_p^2(\alpha)$ da una región de confianza para μ de nivel de confianza $1 - \alpha$. $\chi_p^2(\alpha)$ es el punto $1 - \alpha$ de la distribución χ_p^2 .

Caso de dos muestras

Un tema similar puede ser útil para problemas que sigan con dos muestras. Supongamos que tenemos una muestra $\{\mathbf{X}_\alpha^{(1)}\}$ ($\alpha = 1, \dots, N_1$) de la distribución $N(\mu^{(1)}, \Sigma)$ y una muestra $\{\mathbf{X}_\alpha^{(2)}\}$ ($\alpha = 1, \dots, N_2$) de una segunda población normal $N(\mu^{(2)}, \Sigma)$ ambas con la misma matriz de covarianza. Entonces las dos medias son tales

$$\bar{x}^{(1)} = \frac{1}{N_1} \sum_{\alpha=1}^{N_1} \mathbf{X}_\alpha^{(1)} \quad \bar{x}^{(2)} = \frac{1}{N_2} \sum_{\alpha=1}^{N_2} \mathbf{X}_\alpha^{(2)}$$

se distribuirán independientemente $N(\mu^{(1)}, (\frac{1}{N_1}) \Sigma)$ y $N(\mu^{(2)}, (\frac{1}{N_2}) \Sigma)$. Esperimentalmente, la diferencia entre ambas medias $y = \bar{x}^{(1)} - \bar{x}^{(2)}$ se distribuye $N[V, (\frac{1}{N_1} + \frac{1}{N_2}) \Sigma]$, donde $V = \mu^{(1)} - \mu^{(2)}$. Así

$$\frac{N_1 N_2}{N_1 + N_2} (y - V)^T \Sigma^{-1} (y - V) \leq \chi_p^2(\alpha)$$

es una región de confianza para la diferencia V entre las dos medias media y una región crítica para contrastar la hipótesis $H_0: \mu^{(1)} = \mu^{(2)}$ viene dada por

$$\frac{N_1 N_2}{N_1 + N_2} (\bar{x}^{(1)} - \bar{x}^{(2)})^T \Sigma^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) \geq \chi_p^2(\alpha).$$

Mahalanobis (1930) sugiere la utilización de $(\mu^{(1)} - \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)})$ como una medida de la similitud entre las dos poblaciones.

Estadísticos suficientes para $\mu \gamma \Sigma$

Mos demostrando que

$$\sum_{\alpha} (x_{\alpha} - \mu)(x_{\alpha} - \mu)' = A + N(\bar{x} - \mu)(\bar{x} - \mu)' \quad \gamma$$

$$\sum_{\alpha} (x_{\alpha} - \mu)' \Sigma^{-1} (x_{\alpha} - \mu) = \text{tr}(\Sigma^{-1} A) + N(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu)$$

Si la dimensión de x_1, \dots, x_N podemos escribir como

$$k \exp \left\{ -\frac{1}{2} \left[N(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu) + \text{tr}(\Sigma^{-1} A) \right] \right\} = k_1 \exp \left\{ -\frac{1}{2} N(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu) \right\} k_2 \exp \left\{ -\frac{1}{2} \text{tr}(\Sigma^{-1} A) \right\}$$

Por tanto $\bar{x} \gamma (\frac{1}{N})A$ forman un conjunto suficiente de estadísticos para $\mu \gamma \Sigma$. Si Σ es conocido, \bar{x} es un estadístico suficiente para μ . Sin embargo, si μ es conocido, $(\frac{1}{N})A$ no es un estadístico suficiente para Σ , pero sí lo es $(\frac{1}{N}) \sum_{\alpha=1}^N (x_{\alpha} - \mu)(x_{\alpha} - \mu)'$.

Recordemos que t es un estadístico suficiente para θ si

$$\prod_{\alpha=1}^N f(x_{\alpha}; \theta) = g(t; \theta) \cdot h(x_1, \dots, x_N) \quad \text{una función de } t,$$

donde $f(x_{\alpha}; \theta)$ es la densidad de la α -ésima observación; $g(t; \theta)$ es una función de t y $h(x_1, \dots, x_N)$ no depende de θ (criterio de factorización de Fisher-Neymann).

Si un vector aleatorio q -dimensional γ tiene media v y matriz de covarianzas γ , entonces

$$(\gamma - v)' \gamma (\gamma - v) = q + 2$$

se denominado elipsode de concentración de γ (ver Cramer, 344). La densidad definida mediante una distribución uniforme sobre el interior de este elipsode tiene el mismo vector media y la misma matriz de covarianzas que γ .

Por otra parte, si θ es un vector de q parámetros y t es un vector de estimadores insuficientes de θ basados en N observaciones de una población con matriz de covarianzas γ , entonces el elipsode

$$N(t - \theta)' \in \left[\frac{\partial \log f}{\partial \theta} \right] \left[\frac{\partial \log f}{\partial \theta} \right]' (t - \theta) = q + 2$$

está enteramente contenido en el elipsode de concentración de t (ver Cramer p. 566). Si este último elipsode ~~desconocido~~ coincide con el de concentración de t , entonces se dice que t es eficiente. De general, el cuadrado de la varianza del volumen de este último elipsode y el del de concentración se define como la eficiencia relativa de t . En el caso de una distribución normal multivariante, si $\theta = \mu$, el vector de las medias muestrales \bar{x} es eficiente. Si θ vuelve a μ y a Σ , entonces \bar{x} y Σ tienen una eficiencia relativa igual a $[(N-1)/N]^{p(p+1)/2}$.

En efecto

$$\log f = \log \left[\frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \right] - \frac{1}{2} (x - \mu)' \Sigma^{-1} (x - \mu)$$

$$\frac{\partial \log f}{\partial \mu} = -\frac{1}{2} [-2 \Sigma^{-1} (x - \mu)] \quad \gamma \text{ de aquí} \quad E \left[\frac{\partial \log f}{\partial \theta} \right] \left[\frac{\partial \log f}{\partial \theta} \right]' = E \left[(\Sigma^{-1} (x - \mu)) (\Sigma^{-1} (x - \mu))' \right] = \Sigma^{-1} \cdot E(x - \mu)(x - \mu)' \cdot \Sigma^{-1} = \Sigma^{-1}$$

entonces el elipsode correspondiente es

$$N(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu) = q + 2$$

pero $\bar{x} \sim N(\mu, \frac{1}{N} \Sigma)$, entonces el elipsode de concentración viene dado por

$$\frac{N(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu)}{N-1} = N(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu) = q + 2 \quad \text{ambas coinciden.}$$

Con frecuencia podemos encontraros con matrices de datos en las que al faltar algunas observaciones ponen en entredicho la utilización de las técnicas habituales para la obtención de los correspondientes estimadores de μ y Σ . Situaciones de este tipo pueden presentarse por ejemplo, cuando algunos de los animales en estudio en una experimentación de laboratorio fallecen por causas ajenas a la experiencia, cuando en grandes investigaciones interdisciplinarias surgen nuevas variables a medida que progresó el estudio. En talquier caso, es esencial que las causas que originan las pérdidas de datos sean completamente independientes de la naturaleza o de los valores de las variables estudiadas. Si el número de lecturas de observación completas es pequeño y el resto de la colección de datos es apreciable, preferiremos utilizar métodos de estimación y contrastes de hipótesis que optimicen el uso de la información disponible.

Las estimaciones máximos-verosímiles del vector media y de la matriz de covarianzas de una distribución multinomial mediante una matriz de datos incompleta con un modelo general aleatorio induce a sistemas de cuestiones no lineales cuya solución implica técnicas de análisis numérico. Pueden consultarse en este caso los trabajos de Wilks (1932), Elashoff y Afifi (1966), Timm (1970), Hartley and Hocking (1971) y Basilecas (1972).

Un caso especial de pérdida de datos permitirá el cálculo directo de las estimaciones máximos-verosímiles de μ y Σ . Se trata del caso en que la matriz de datos obedece al modelo conocido con el nombre de "monótono" o "anidado" y que es de la forma

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_{11} & \mathbf{X}_{12} & \cdots & \mathbf{X}_{1, k-1} & \mathbf{X}_{1, k} \\ \mathbf{X}_{21} & \mathbf{X}_{22} & \cdots & \mathbf{X}_{2, k-1} & - \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \mathbf{X}_{k-1, 1} & \mathbf{X}_{k-1, 2} & \cdots & - & - \\ \mathbf{X}_{k, 1} & - & \cdots & - & - \end{bmatrix}$$

en la que los guiones indican bloques de observaciones perdidas. \mathbf{X}_{ij} es una submatriz $N_i \times r_j$, donde $\sum_{i=1}^k N_i = N$, número total de unidades muestrales independientes y $\sum_{j=1}^k r_j = p$, el número de repuestas. Concretamente el vector media aparece formado de la forma $\mu = [\mu_1, \mu_2, \dots, \mu_k]$ y la matriz de covarianzas aparece también fraccionada en matrices Σ_{ij} de dimensiones $r_i \times r_j$, $i, j = 1, \dots, k$. Como consecuencia de la monotonía del modelo de la matriz de datos podemos simbolizar la verosimilitud de la muestra como

$$L(\mu, \Sigma) = f(\mathbf{X}) = \left[\prod_{i=1}^k f(\mathbf{X}_{ii}) \right] \cdot \left[\prod_{i=1}^k f(\mathbf{X}_{i2}/\mathbf{X}_{ii}) \right] \cdot \left[\prod_{i=1}^{k-1} f(\mathbf{X}_{i3}/\mathbf{X}_{ii}, \mathbf{X}_{ii}) \right] \cdots f(\mathbf{X}_{kk}/\mathbf{X}_{ii} \cdots \mathbf{X}_{(k-1)k})$$

en la que la parte derecha de la igualdad aparece enteíminos de densidades condicionales a fin de evitar una notación excesivamente complicada. $f(\mathbf{X}_{ij}/\mathbf{X}_{ii}, \dots, \mathbf{X}_{(i-1)i})$ es la verosimilitud condicional de la i,j -suma submatriz, cuya expresión puede obtenerse de la forma usual mediante el producto de N_i densidades multinomiales r_i -dimensionales e independientes cuyos parámetros se obtienen aplicando las expresiones correspondientes a las densidades condicionales. Se puede mediante la maximización necesaria de los factores que aparecen en los enrelos: la primera de estas operaciones conduce a los estimadores usuales $\hat{\mu}_i$ y $\hat{\Sigma}_{ii}$ utilizando para ello las N_i unidades muestrales. El segundo factor proporciona estimaciones de $\mu_2 - \hat{\Sigma}_{12} \hat{\Sigma}_{11}^{-1} \mu_1$, de los parámetros de regresión $\hat{\Sigma}_{12} \hat{\Sigma}_{11}^{-1}$ y de la matriz de covarianzas condicional $\Sigma_{22} - \hat{\Sigma}_{12} \hat{\Sigma}_{11}^{-1} \hat{\Sigma}_{12}$. Con la ayuda de las estimaciones pioneras de μ_1 y $\hat{\Sigma}_{11}$ podemos obtener, a partir de los anteriores, las estimaciones máximos-verosímiles de μ_2 , $\hat{\Sigma}_{12}$ y Σ_{22} . Continuamos de esta forma hasta que hayan sido estimados los parámetros incondicionales del k -suma conjunto. Este método de aproximación fue desarrollado por Anderson (1957) y fue extendido a más de dos conjuntos de variables por Bohargava (1962).

A continuación desarrollaremos con detalle el método para el caso más sencillo, aquel en el que el modelo sea formado tan solo por dos conjuntos de variables. Sean $\mathbf{y}' = (\mathbf{x}'_{11}, \mathbf{x}'_{12})$ y $\mathbf{x} = \mathbf{x}_{12}$. Entonces

$$\hat{\mu}_1 = \frac{1}{N} \sum_{i=1}^N y_i, \quad \hat{\Sigma}_{11} = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})(y_i - \bar{y})'$$

estimados en la forma usual a partir del conjunto completo de datos. Para las otras estimaciones tenemos

$$\bar{x} = \frac{1}{N_1} \sum_{i=1}^{N_1} x_i \quad \bar{y}_1 = \frac{1}{N_1} \sum_{i=1}^{N_1} y_i \quad \bar{y}_2 = \frac{1}{N_2} \sum_{i=N_1+1}^N y_i$$

$$A_{11}(N_1) = \sum_{i=1}^{N_1} (x_i - \bar{x})(y_i - \bar{y}_1)' \quad A_{11}(N) = \sum_{i=1}^N (y_i - \bar{y})(y_i - \bar{y})'$$

$$A_{22} = \sum_{i=1}^{N_1} (x_i - \bar{x})(x_i - \bar{x})' \quad A_{12} = \sum_{i=1}^{N_1} (y_i - \bar{y}_1)(x_i - \bar{x})'$$

$$B = A_{11}^{-1}(N_1) A_{12}$$

las estimaciones de los parámetros restantes son

$$\hat{\mu}_2 = \bar{x} - \left(\frac{N_2}{N} \right) B' (\bar{y}_1 - \bar{y}_2)$$

$$\hat{\Sigma}_{22} = \frac{1}{N_1} [A_{22} - A_{12} A_{11}^{-1}(N_1) A_{12}] + \frac{1}{N} B' A_{11}(N) B$$

$$\hat{\Sigma}_{12} = \frac{1}{N} A_{11}(N) A_{11}^{-1}(N_1) A_{12}$$

Las esperanzas y algunos momentos de segundo orden de estas estimaciones han sido calculadas por Morrison (1971). En particular $\hat{\mu}_2$ y $[N/(N-1)] \hat{\Sigma}_{12}$ son interesantes, mientras que es posible definir los términos de los distintos términos de $\hat{\Sigma}_{22}$ para obtener el siguiente estimador deseado:

$$\hat{\Sigma}_{22}(z) = \frac{1}{N_1 - r_1 - 1} \left[1 - \frac{r_1}{N_1 - r_1 - 2} + \frac{r_1(r_1+1)}{(N_1 - r_1 - 2)(N-1)} \right] [A_{22} - A_{12} A_{11}^{-1}(N_1) A_{12}] + \frac{1}{N-1} B' A_{11}(N) B$$

Los valores de las varianzas de las estimaciones de μ_2 , Σ_{22} y Σ_{12} para N_1, N pequeños, indican que estas estimaciones son menos eficientes que las convencionales, obtenidas a partir, normalmente, de los primeros N_1 observaciones completas cuando las correlaciones entre los dos conjuntos de variables son bajas. Además para la elección del tipo de estimación más conveniente han sido ~~discutidas~~ indicadas en la referencia anterior de Morrison (1971).

Ejemplo. - Una universidad utiliza una ecuación de regresión múltiple para estimar los índices puntuales de acceso (IPA) de los solicitantes a partir de sus rangos de clase, tests de aptitud scolastica (TAS) y otros tipos de tests de interés general. Las estimaciones de los IPA se miden en tres formularios suministrados a los solicitantes para uso de los miembros del comité de admisións. Una muestra de $N=34$ admisiones evaluadas por un miembro de la Facultad contiene cinco de ellas con el correspondiente IPA. Sin embargo, todas las admisiones tienen TAS de matemáticas y resultados de tests verbales entre otras medidas de tipo académico. Los datos así presentados son un ejemplo de modelo monotorio de observaciones incompletas, con $r_1=2$ respuestas completas y $r_2=4$ incompletas, $N_1=29$ unidades muestrales completas y $N_2=5$ incompletas. Se supone que las puntuaciones de los tests verbales (y_1), del TAS de matemáticas (y_2) y del IPA (x) son una muestra trivariante de una distribución normal cuyos parámetros se estiman mediante los métodos que acabamos de exponer.

Comenzaremos preparando una representación gráfica informal de los valores del IPA frente a los resultados del TAS para los 29 vectores completos. Esta representación indica una ligera correlación positiva y parece que, en estas condiciones, las estimaciones basadas en observaciones incompletas hayan de ser más eficientes que las estimaciones basadas en los 29 resultados de los IPA. Consideremos pues

$$\bar{x} = 2.43 \quad \bar{y}_1 = \begin{bmatrix} 56.38 \\ 61.31 \end{bmatrix} \quad \bar{y}_2 = \begin{bmatrix} 55.80 \\ 55.60 \end{bmatrix} \quad \bar{y} = \begin{bmatrix} 56.29 \\ 60.47 \end{bmatrix}$$

$$A_{11}(N_1) = \begin{bmatrix} 1292.83 & 206.59 \\ 206.59 & 1328.21 \end{bmatrix} \quad A_{11}(N) = \begin{bmatrix} 1109.06 & 238.29 \\ 238.29 & 1668.47 \end{bmatrix} \quad a_{22} = 2.9455$$

$$A_{11}^{-1}(N_1) = 10^{-4} \begin{bmatrix} 7.9321 & -1.2338 \\ -1.2338 & 7.7208 \end{bmatrix} \quad B = 10^{-2} \begin{bmatrix} 1.6862 \\ 2.9142 \end{bmatrix}$$

y las estimaciones máximos-ventimiles de los parámetros de IPA son

$$\hat{\mu}_x = 2.40 \quad \hat{\sigma}_x^2 = 0.1034$$

La estimación de la media es ligeramente menor que la estimación usual basada en datos completos, \bar{x} . Para poder establecer comparaciones con $\hat{\sigma}_x^2$ a continuación presentamos distintas estimaciones alternativas de la varianza:

Estimación	Valor
MLE Univariante resgada s_x^2/n	0.1016
MLE imprecisa datos incompletos	0.1067
MLE univariante resgada $s_x^2/(N-1)$	0.1082

la estimación basada en los datos incompletos, tanto en la resgada como la imprecisa, es ligeramente mayor que su correspondiente contrapartida univariante (basada en los datos completos).

Capítulo 3

Coeficientes de correlación muestrales

COEFICIENTE DE CORRELACIONES MUESTRALES

1. INTRODUCCION

Se pretende en este capítulo el estudio dels coeficientes de correlación muestrales que no más que las cantidades equivalentes a los coeficientes de correlación poblacional definidos en el Capítulo anterior. Utilizaremos los conceptos de probabilidad y teoría del test de hipótesis y regiones de confianza para determinar situaciones de interés.

En el caso de distribuciones univariadas conjuntas los coeficientes de correlación son la medida natural de la dependencia entre variables. Para los estimadores de los correlaciones poblacionales utilizaremos los correspondientes muestrales y justificaremos el porqué.

Comencemos recordando la diferencia que existe entre los conceptos de regresión y correlación. Dicha teoría de la regresión una variable se considera aleatoria o dependiente de otras fijas o independientes. En teoría de la correlación consideramos varias variables como aleatorias, las tratamos todas ellas simultáneamente. Si consideramos con una distribución conjunta normal y mantenemos fijas todas las variables excepto una, obtendremos el modelo mínimo cuadrático puesto que la esperanza de la variable aleatoria en la distribución condicional es una función lineal de las variables que permanecen fijas. Los coeficientes de regresión muestrales obtendrán mediante el método de los mínimos cuadrados, una función de las varianzas, muestrales y de las covarianzas.

Si contestáramos la hipótesis de independencia negaríamos a través de analogías tanto el punto de vista del otro (es decir, distribución conjunta normal o distribución condicional). La distribución de probabilidad bajo la hipótesis nula es la misma. La distribución de los autores del test cuando la hipótesis nula no se rechaza en los dos casos. Si todas las variables pueden considerarse aleatorias utilizaremos la teoría de la correlación tal como aparece en continuación, si solo una variable es aleatoria, utilizaremos la teoría de los mínimos cuadrados (posteriormente en otro capítulo).

2. COEFICIENTE DE CORRELACION DE UNA MUESTRA BIVARIANTE

Como en el capítulo anterior que una estimación máxima-razonable del coeficiente de correlación entre los componentes Σ_i y Σ_j del vector aleatorio Σ , cuando utilizamos una muestra de tamaño N (x_1, \dots, x_N) es

$$r_{ij} = \frac{\sum_{\alpha=1}^N (x_{i\alpha} - \bar{x}_i)(x_{j\alpha} - \bar{x}_j)}{\sqrt{\sum_{\alpha=1}^N (x_{i\alpha} - \bar{x}_i)^2} \sqrt{\sum_{\alpha=1}^N (x_{j\alpha} - \bar{x}_j)^2}}$$

Vamos a determinar la distribución de r_{ij} cuando la correlación poblacional entre Σ_i y Σ_j es cero.

Sabemos como utilizar el coeficiente de correlación muestral para contrastar que el poblacional es cero. Desarrollaremos la teoría, por comodidad, para r_{12} . Como r_{12} depende sólo de los dos primeros componentes de cada x_α , bastará con considerar solamente la distribución conjunta de $(x_{11}, x_{12}), (x_{12}, x_{22}), \dots, (x_{1N}, x_{2N})$. Podemos entonces reformular el problema anterior en forma de distribución normal bivariante. Sean x_1^*, \dots, x_N^* observaciones restringidas de

$$N \begin{bmatrix} (\mu_1) \\ (\mu_2) \end{bmatrix}, \begin{bmatrix} \sigma_1^2 & \rho_1 \sigma_1 \sigma_2 \\ \rho_1 \sigma_1 \sigma_2 & \sigma_2^2 \end{bmatrix}$$

Sea

$$r = r_{12} = \frac{a_{12}}{\sqrt{a_{11} a_{22}}} \quad \text{con} \quad a_{ij} = \sum_{\alpha=1}^N (x_{i\alpha} - \bar{x}_i)(x_{j\alpha} - \bar{x}_j) \quad i, j = 1, 2$$

(cuando $x_{i\alpha}$ la i -ésima componente de x_α^*).

Sabemos que a_{ij} se distribuye como $\sum_{\alpha=1}^n z_{i\alpha} z_{j\alpha}$ $i, j = 1, 2$, donde $n = N - 1$ y $(z_{1\alpha}, z_{2\alpha})$ se

distribuye de acuerdo con una normal bivariante

$$N \begin{bmatrix} (0) \\ (0) \end{bmatrix}, \begin{bmatrix} \sigma_1^2 & \rho_1 \sigma_1 \sigma_2 \\ \rho_1 \sigma_1 \sigma_2 & \sigma_2^2 \end{bmatrix}$$

y independientemente de $(z_{1\alpha}, z_{2\alpha})$, $\alpha \neq \beta$.

Sea $Z'_i = (z_{i1}, \dots, z_{in})$, $i=1,2$. Estas dos vetores pueden representarse en un espacio n -dimensional.

El coeficiente de correlación es el coseno del ángulo θ entre Z_1 y Z_2 .

Para encontrar la distribución de $\cos \theta$ necesitamos primera la de $\cot \theta$. Como $Z_2 = (Z_2 - bZ_1) + bZ_1$, podemos b como una función de Z_1 , Z_2 tal que $Z_2 - bZ_1$ sea orthogonal a bZ_1 . Entonces

$$\cot \theta = b \sqrt{z_1' z_1 / (z_2' - b z_1)' (z_2' - b z_1)}$$

Si Z_1 permanece fijo podemos girar los ejes de manera que el primer eje de coordenadas coincida con Z_1 . Entonces bZ_1 tiene otra coordenada diferente de cero y $Z_2 - bZ_1$ tendrá la primera coordenada igual a cero.

Demostremos que $\cot \theta$ es proporcional a una variable t cuando $\rho=0$.

La distribución condicional de Z_{2x} dado $Z_{1x} = z_{1x}$ es $N(\beta z_{1x}, \sigma^2)$, donde $\beta = \rho \sigma_2 / \sigma_1$ y $\sigma^2 = \sigma_2^2(1-\rho^2)$ como vimos en el momento. La distribución conjunta de Z_2 dado $Z_1 = z_1$ es $N(\beta z_1, \sigma^2 I)$ puesto que las Z_{2x} son independientes. Ahora bien, la densidad conjunta de Z_1, Z_2 es

$$\prod_{\alpha=1}^n n \left[\begin{pmatrix} z_{1\alpha} \\ z_{2\alpha} \end{pmatrix} \middle| \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix} \right]$$

La marginal de Z_1 viene dada por

$$\prod_{\alpha=1}^n n(z_{1\alpha} | 0, \sigma_1^2) = n(z_1 | 0, \sigma_1^2 I)$$

por tanto la condicional de Z_2 dado $Z_1 = z_1$, máximamente de la conjunta por la marginal de Z_1 en z_1 , se da por

$$\prod_{\alpha=1}^n \left\{ n \left[\begin{pmatrix} z_{1\alpha} \\ z_{2\alpha} \end{pmatrix} \middle| \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix} \right] / n(z_1 | 0, \sigma_1^2) \right\} = \prod_{\alpha=1}^n n(z_{2\alpha} | \beta z_{1\alpha}, \sigma^2).$$

Sea ahora $b = Z_2' z_1 / z_1' z_1 (= a_{21}/a_{11})$, entonces $bZ_1'(Z_2 - bZ_1) = 0$, y sea $V = (Z_2 - bZ_1)'(Z_2 - bZ_1) = Z_2' Z_2 - b^2 Z_1' Z_1 (= a_{22} - a_{12}^2/a_{11})$. Entonces $\cot \theta = b \sqrt{\sigma_1^2 / V}$. La rotación de los ejes coordenados关于我们的假设导致一个矩阵 $(n \times n)$ 正交的， C ，唯一非零行向量 $(\frac{1}{c}) Z_1'$ ，其中 $c^2 = z_1' z_1$.

Podemos ahora aplicar un teorema del capítulo anterior que hace referencia a una matriz formada por vectores ortogonales, si tenemos $X_\alpha = Z_{2\alpha}$ y $Y_\alpha = \sum_{\beta=1}^n C_{\alpha\beta} Z_{1\beta}$. Entonces los $\{Y_\alpha\}$ son independientes y se distribuyen normalmente con varianza σ^2 y media

$$E(Y_1) = \sum_{\beta=1}^n C_{1\beta} E(Z_{1\beta}) = \sum_{\beta=1}^n C_{1\beta} \beta z_{1\beta} = \frac{\beta}{c} \sum_{\beta=1}^n z_{1\beta}^2 = \beta c$$

$$E(Y_\alpha) = \sum_{\beta=1}^n C_{\alpha\beta} E(Z_{1\beta}) = \sum_{\beta=1}^n C_{\alpha\beta} \beta z_{1\beta} = \beta c \sum_{\beta=1}^n C_{\alpha\beta} = 0 \quad , \quad \alpha \neq 1.$$

Tenemos $b = \sum_{\alpha} Z_{2\alpha} z_{1\alpha} / \sum_{\alpha} z_{1\alpha}^2 = c \sum_{\alpha} Z_{2\alpha} c_{1\alpha} / \sum_{\alpha} z_{1\alpha}^2 = c Y_1 / c^2 = Y_1 / c^2 = Y_1 / c$, del teorema que presentábamos anteriormente del teorema antes utilizado podemos deducir

$$V = \sum_{\alpha} Z_{2\alpha}^2 - b^2 \sum_{\alpha} z_{1\alpha}^2 = \sum_{\alpha} Y_\alpha^2 - Y_1^2 = \sum_{\alpha=2}^n Y_\alpha^2$$

que es independiente de b .

Lema. — Si $(Z_{1\alpha}, Z_{2\alpha})$, $\alpha=1, \dots, n$, son independientes cada para con la distribución normal conjunta de media $\mu = [0, 0]$ y $S = \begin{bmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{bmatrix}$, entonces la distribución condicional de $b = \sum_{\alpha} Z_{2\alpha} z_{1\alpha} / \sum_{\alpha} z_{1\alpha}^2$ y $V/\sigma^2 = \sum_{\alpha} (Z_{2\alpha} - b z_{1\alpha})^2 / \sigma^2$ dado $Z_{1\alpha} = z_{1\alpha}$ ($\alpha=1, \dots, n$) es $N(\beta, \sigma^2/c^2)$, $c^2 = \sum_{\alpha} z_{1\alpha}^2$ y χ^2 con $n-1$ g.l. respectivamente y ademas b y V son independientes.

Si $\rho_{ij} = 0$, entonces $\beta_{ij} = 0$, por tanto la redistribuye condicionalmente $N(0, \sigma^2/c^2)$

$$\frac{cb/\sigma}{\sqrt{\frac{\sigma^2}{n-1}}} = \frac{cb}{\sqrt{\frac{\sigma^2}{n-1}}}$$

Tiene una distribución condicional t con $n-1$ g.l. Ahora bien, esta variable aleatoria \Rightarrow

$$\sqrt{n-1} \cdot \frac{(a_{11})^{1/2} a_{12}/a_{11}}{\sqrt{a_{11} - a_{12}^2/a_{11}}} = \sqrt{n-1} \frac{a_{12}/\sqrt{a_{11}a_{22}}}{\sqrt{1 - [a_{12}^2/(a_{11}a_{22})]}} = \sqrt{n-1} \frac{r}{\sqrt{1-r^2}}$$

Aquí pues $\sqrt{n-1} r / \sqrt{1-r^2}$ tiene una distribución condicional t con $n-1$ g.l. La densidad de t es

$$\frac{\Gamma(\frac{1}{2}n)}{\sqrt{n-1} \Gamma[\frac{1}{2}(n-1)] \sqrt{n}} \left(1 + \frac{t^2}{n-1}\right)^{-\frac{1}{2}n}$$

y la densidad de $r / \sqrt{1-r^2}$ viene dada por

$$\frac{\Gamma(\frac{1}{2}n)}{\Gamma(\frac{1}{2}(n-1)) \sqrt{n}} (1+r^2)^{-\frac{1}{2}n}$$

Puesto que $w = r(1-r^2)^{-\frac{1}{2}}$ y $dw/dr = (1-r^2)^{-\frac{3}{2}}$, la densidad de w vendrá dada por (dividiendo

$$\frac{\Gamma(\frac{1}{2}(n-1))}{\Gamma(\frac{1}{2}(n-2)) \sqrt{n}} (1-r^2)^{\frac{1}{2}(n-4)}$$

No diremos que esta es la densidad de r para z_1 fijo. Pero dado que no depende para nada de z_1 , ni tampoco la marginal de r.

TEOREMA .- Sean $Z_{1,1}, \dots, Z_{1,n}$ independientes, cada uno con distribución $N(\mu, \Sigma)$. Si $\rho_{ij} = 0$, la densidad de r_{ij} definida como ante, viene dada por la última expresión anterior.

Observamos que la densidad de r es simétrica respecto del origen. Además, para $N > 4$, tiene un modo en $r=0$ y presenta raíces en los puntos ± 1 cuya orden es $\frac{1}{2}(N-5)$ para N impar y $\frac{1}{2}N-3$ para N par. Puesto que la densidad es par, los momentos impares son ceros, en particular la media es cero. Los momentos pares se pueden calcular por integración (dividiendo el cuadrado $x=r^2$ y utilizando la función ρ), y obtiene $E[r^{2m}]$ mediante la expresión $E[r^{2m}] = \Gamma(\frac{1}{2}(N-1)) \Gamma(\frac{1}{2}+m) / \{\sqrt{n} \Gamma(\frac{1}{2}(N-1)+m)\}$, en particular la variancia ($m=1$) es $1/(N-1)$.

El uso más importante del anterior teorema es buscar puntos de significación para contrastar la hipótesis de que una par de variables están vinculadas. Consideremos la hipótesis

$$H_0: \rho_{ij} = 0$$

para algún par (i, j) . Parece razonable rechazar H_0 si r_{ij} difiere mucho de cero, pero como cuantificar este "mucha".

Supongamos que queremos a contrastar H_0 frente a $H_1: \rho_{ij} > 0$. Reduciremos H_0 a $r_{ij} < r_0$ mayor que una determinada cantidad r_0 . La probabilidad de rechazar H_0 siendo cierta H_1 es

$$\int_{r_0}^1 k_N(r) dr$$

donde $k_N(r)$ es la densidad del coeficiente del error estándar basado en N observaciones. Elejimos r_0 de manera que la anterior probabilidad coincida con el nivel de significación deseado. Si la alternativa es de la forma $\rho_{ij} < 0$, entonces rechazaremos para $r_{ij} > r_0$.

Para el caso de una alternativa bilateral, $\rho_{ij} \neq 0$. Entonces rechazaremos H_0 si $r_{ij} > r_1$ o $r_{ij} < -r_1$. La probabilidad de rechazo para H_0 , siendo clásica, vendrá dada por

$$\int_{-r_1}^{r_1} K_N(r) dr + \int_{r_1}^1 K_N(r) dr.$$

Existen tablas (Fisher y Yates, 1942) para la distribución de r . De cualquier forma, teniendo en mente que $\sqrt{N-2} r / \sqrt{1-r^2}$ tiene una distribución t con $N-2$ g.l., podemos usar alternativamente esta distribución para la obtención de r_1 y r_2 . Así, para alternativas del tipo $\rho_{ij} \neq 0$, rechazaremos H_0 si

$$\sqrt{N-2} \frac{|r_{ij}|}{\sqrt{1-r_{ij}^2}} > t_{N-2}(\alpha)$$

de forma análoga a lo visto en los otros casos.

Por otra parte, en el transcurso de la deducción del test anterior queda claro que el mismo procedimiento puede ser utilizado para contrastar la hipótesis de que la regresión de Z_2 sobre Z_1 es nula. En términos de las observaciones originales, tenemos

$$\sqrt{N-2} \frac{r}{\sqrt{1-r^2}} = \frac{b \sqrt{\sum_{\alpha} (x_{1\alpha} - \bar{x}_1)^2}}{\sqrt{\sum_{\alpha} [x_{2\alpha} - \bar{x}_2 - b(x_{1\alpha} - \bar{x}_1)]^2 / (N-2)}}$$

donde $b = \sum_{\alpha} (x_{2\alpha} - \bar{x}_2)(x_{1\alpha} - \bar{x}_1) / \sum_{\alpha} (x_{1\alpha} - \bar{x}_1)^2$ es el coeficiente de regresión mínimo cuadrático de $x_{2\alpha}$ sobre $x_{1\alpha}$. Ya hemos visto que el test $\rho_{12}=0$ es equivalente al test de que la regresión de Z_2 sobre Z_1 es nula (es decir, que $\rho_{12}\delta_2/\delta_1=0$).

Distribución cuando $\rho \neq 0$. Test de hipótesis y regiones de confianza.

En este caso deberemos en primer lugar obtener la distribución conjunta de a_{11}, a_{12} y a_{21} . La vemos como que las variables, para Z_1 fijo, de $b = a_{11}/a_{11} + \delta/\delta_2 = (a_{21} - a_{11}^2/a_{11})/\delta^2$ son independientes, más concretamente $N(\beta, \delta^2/c^2) \sim \chi^2$ con $n-1$ g.l. respectivamente. Desstando la densidad de la χ^2_{n-1} mediante $g_{n-1}(w)$, la conjunta correspondiente de b y $\sqrt{a_{11}}$

$$n(b|\beta, \delta^2/a_{11}) g_{n-1}(\delta/\delta_2)/\delta^2$$

La conjunta de $Z_1, b, \sqrt{a_{11}}$ vendrá dada por

$$n(z_1|0, \delta_1^2 I) \cdot n(b|\beta, \delta^2/a_{11}) \cdot g_{n-1}(\delta/\delta_2)/\delta^2.$$

La densidad marginal de $Z_1, b, \sqrt{a_{11}} = a_{11}/\delta^2$, se puede obtener de mediante

$$\int_{Z_1' Z_1 = a_{11}} \dots \int n(z_1|0, \delta_1^2 I) dz_1$$

y como resultado de la suma de cuadrados de n variables $(0, 1)$, tendremos que a_{11}' sigue una χ^2 con n g.l., es decir

$$\frac{1}{\delta^2} g_{n-1}\left(\frac{a_{11}}{\delta^2}\right) = \int_{Z_1' Z_1 = a_{11}} \dots \int n(z_1|0, \delta_1^2 I) dz_1.$$

donde dW es el diferencial de volumen estandarizado, más concretamente es volumen sobre la esfera $Z_1' Z_1 = a_{11}$. La densidad conjunta de $b, \sqrt{a_{11}}$ es

$$\int_{Z_1' Z_1 = a_{11}} \dots \int n(b|\beta, \delta^2/a_{11}) g_{n-1}(\delta/\delta_2) \frac{1}{\delta^2} n(z_1|0, \delta_1^2 I) dz_1 =$$

$$= g_{n_1}(a_{11}/\sigma_1^2) \cdot n(b) \beta, \sigma^2/a_{11} \cdot g_{n-1}(v/\sigma_2) \cdot (\sigma^2/\sigma_2^2) =$$

$$= \frac{a_{11}^{\frac{1}{2}(n-1)}}{(2\sigma_1^2)^{\frac{1}{2}n} \Gamma(\frac{1}{2}n)} \exp\left(-\frac{1}{2\sigma_1^2} a_{11}\right) \cdot \frac{\sqrt{a_{11}}}{\sqrt{2\pi\sigma_2^2}} \exp\left[-\frac{a_{11}}{2\sigma_2^2} (b-\beta)^2\right] \cdot \frac{1}{(2\sigma_2^2)^{\frac{1}{2}(n-1)} \Gamma(\frac{1}{2}(n-1))} v^{\frac{1}{2}(n-3)} \exp\left(-\frac{1}{2\sigma_2^2} v\right)$$

Hagamos ahora $b = a_{11}/a_{11}$, $v = a_{22} - a_{12}^2/a_{11}$. El Jacobiano de la transformación

$$\frac{\partial(b, v)}{\partial(a_{11}, a_{22})} = \begin{vmatrix} \frac{1}{a_{11}} & 0 \\ -2\frac{a_{12}}{a_{11}} & 1 \end{vmatrix} = \frac{1}{a_{11}}.$$

Ora la densidad para a_{11}, a_{12}, a_{22} es

$$\frac{a_{11}^{\frac{1}{2}(n-3)} \left(\frac{a_{11} a_{12} - a_{12}^2}{a_{11}} \right)^{\frac{1}{2}(n-3)}}{2^n \sigma_1^n \left(\frac{\sigma_1^2 \sigma_2^2 - \sigma_1^2 \sigma_1^2 \sigma_2^2}{\sigma_1^2} \right) \sqrt{n} \Gamma(\frac{1}{2}n) \Gamma(\frac{1}{2}(n-1))} e^{-\frac{1}{2}Q}$$

donde

$$Q = \frac{a_{11}}{\sigma_1^2} + \frac{a_{11}}{\sigma_2^2} \left(\frac{a_{12}^2}{a_{11}^2} - 2p \frac{\sigma_1 \sigma_2}{\sigma_1^2} \cdot \frac{a_{12}}{a_{11}} + p^2 \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^4} \right) + \frac{1}{\sigma_2^2} \left(a_{22} - \frac{a_{12}^2}{a_{11}} \right) =$$

$$= a_{11} \left[\frac{1}{\sigma_1^2} + \frac{p^2 \sigma_1^2 \sigma_2^2}{\sigma_1^4 \sigma_2^2 (1-p^2)} \right] - 2a_{12} \frac{p \sigma_1 \sigma_2}{\sigma_1 \sigma_2^2 (1-p^2)} + \frac{a_{22}}{\sigma_2^2 (1-p^2)} =$$

$$= \frac{1}{1-p^2} \left(\frac{a_{11}}{\sigma_1^2} - 2p \frac{a_{12}}{\sigma_1 \sigma_2} + \frac{a_{22}}{\sigma_2^2} \right).$$

La densidad puede también escribirse

$$\frac{|A|^{\frac{1}{2}(n-3)} e^{-\frac{1}{2}Q}}{2^n |\Sigma|^{\frac{1}{2}n} \sqrt{n} \Gamma(\frac{1}{2}n) \Gamma(\frac{1}{2}(n-1))}$$

que es un caso particular de la distribución de Wishart que obtendremos en el capítulo posterior.

Ahora la densidad de a_{11}, a_{22} , $r = a_{12}/\sqrt{a_{11} a_{22}}$ ($a_{12} = \sqrt{a_{11} a_{22}}$) vendrá dada por

$$\frac{a_{11}^{\frac{1}{2}n-1} a_{22}^{\frac{1}{2}n-1} (1-p^2)^{\frac{1}{2}(n-3)}}{2^n [\sigma_1^2 \sigma_2^2 (1-p^2)]^{\frac{1}{2}n} \sqrt{n} \Gamma(\frac{1}{2}n) \Gamma(\frac{1}{2}(n-1))} e^{-\frac{1}{2}Q}$$

donde

$$Q = \frac{1}{1-p^2} \left(\frac{a_{11}}{\sigma_1^2} - 2pr \frac{\sqrt{a_{11} a_{22}}}{\sigma_1 \sigma_2} + \frac{a_{22}}{\sigma_2^2} \right)$$

para obtener la densidad de r debemos integrar la anterior expresión respecto a a_{11} y a_{22} sobre la recta real positiva. Podemos hacerlo de varias maneras, que dan lugar a diferentes expresiones para la densidad. Indicaremos aquí el método más directo. Desarrollaremos en primer lugar parte de la expresión

$$\exp\left[\frac{er\sqrt{a_{11} a_{22}}}{(1-p^2) \sigma_1 \sigma_2}\right] = \sum_{\alpha=0}^{\infty} \frac{(er\sqrt{a_{11} a_{22}})^{\alpha}}{\alpha! [\sigma_1 \sigma_2 (1-p^2)]^{\alpha}}.$$

La mera expresión para la densidad de a_{11}, a_{22} y r es

$$\frac{(1-p^2)^{\frac{1}{2}(n-3)}}{\delta_1^{\frac{n}{2}} \delta_2^{\frac{n}{2}} (1-p^2)^{\frac{1}{2}n} 2^n \sqrt{n} \Gamma(\frac{1}{2}n) \Gamma(\frac{1}{2}(n-1))} \sum_{\alpha=0}^{\infty} \frac{(er)^{\alpha}}{\alpha! (1-p^2)^{\alpha} \delta_1^{\alpha} \delta_2^{\alpha}} \cdot \left\{ \exp \left[-\frac{a_{11}}{2(1-p^2) \delta_1^2} \right] a_{11}^{\frac{1}{2}(n+\alpha)-1} \right\} \left\{ \exp \left[-\frac{a_{22}}{2(1-p^2) \delta_2^2} \right] a_{22}^{\frac{1}{2}(n+\alpha)} \right\}.$$

punto que

$$\int_0^{+\infty} a_{11}^{\frac{1}{2}(n+\alpha)-1} \exp \left[-\frac{a_{11}}{2(1-p^2) \delta_1^2} \right] da_{11} = \Gamma\left(\frac{1}{2}(n+\alpha)\right) \cdot [2\delta_1^2(1-p^2)]^{\frac{1}{2}(n+\alpha)}$$

Integrando la densidad (podemos integrar termino a termino) llegamos a

$$\begin{aligned} & \frac{(1-p^2)^{\frac{1}{2}(n-3)}}{\delta_1^{\frac{n}{2}} \delta_2^{\frac{n}{2}} (1-p^2)^{\frac{1}{2}n} 2^n \sqrt{n} \Gamma(\frac{1}{2}n) \Gamma(\frac{1}{2}(n-1))} \sum_{\alpha=0}^{\infty} \frac{(er)^{\alpha}}{\alpha! (1-p^2)^{\alpha} \delta_1^{\alpha} \delta_2^{\alpha}} \cdot \Gamma^2\left[\frac{1}{2}(n+\alpha)\right] \cdot 2^{(n+\alpha)} \delta_1^{(n+\alpha)} \delta_2^{(n+\alpha)} (1-p^2)^{(n+\alpha)} = \\ & = \frac{(1-p^2)^{\frac{1}{2}n} (1-r^2)^{\frac{1}{2}(n-3)}}{\sqrt{n} \Gamma(\frac{1}{2}n) \Gamma(\frac{1}{2}(n-1))} \sum_{\alpha=0}^{\infty} \frac{(2er)^{\alpha}}{\alpha!} r^{\alpha} \left(\frac{1}{2}(n+\alpha)\right) \end{aligned}$$

Utilizando la fórmula $\Gamma(z) \cdot \Gamma(z + \frac{1}{2}) = \sqrt{\pi} \Gamma(2z)/2^{2z-1}$ podemos modificar la constante. Llegaremos entonces al siguiente teorema:

Teoréma . - El coeficiente de correlación en una muestra de tamaño N de una normal bivariante con correlación p se distribuye de la siguiente manera

$$\frac{2^{n-2} (1-p^2)^{\frac{1}{2}n} (1-r^2)^{\frac{1}{2}(n-3)}}{(n-2)! n} \sum_{\alpha=0}^{\infty} \frac{(2er)^{\alpha}}{\alpha!} r^{\alpha} \left(\frac{1}{2}(n+\alpha)\right) \quad \text{donde } n=N-1.$$

La distribución de r fue obtenida por primera vez por Fisher en 1915, quien dio para su densidad la siguiente expresión

$$\frac{(1-p^2)^{\frac{1}{2}n} (1-r^2)^{\frac{1}{2}(n-3)}}{n(n-2)!} \left[\frac{d^{n-1}}{dx^{n-1}} \left\{ \frac{\psi^{-1}(-x)}{\sqrt{1-x^2}} \right\} \right]_{x=r_p}$$

que se obtiene de las expresiones anteriores haciendo los cambios $a_{11}=u e^{r^2}$, $a_{22}=u e^{r^2}$.

Kottingh studió exhaustivamente la distribución de r y recomendó el uso de la expresión

$$\frac{n-1}{\sqrt{2n}} \cdot \frac{\Gamma(n)}{\Gamma(n+\frac{1}{2})} (1-p^2)^{\frac{1}{2}n} (1-r^2)^{\frac{1}{2}(n-3)} (1-pr)^{-n+\frac{1}{2}} F\left(\frac{1}{2}, \frac{1}{2}; n+\frac{1}{2}; \frac{1+pr}{2}\right)$$

donde

$$F(a,b;c;x) = \sum_{j=0}^{\infty} \frac{\Gamma(a+j)}{\Gamma(a)} \cdot \frac{\Gamma(b+j)}{\Gamma(b)} \cdot \frac{\Gamma(c)}{\Gamma(c+j)} \cdot \frac{x^j}{j!} \quad \rightarrow \text{una función hipergeométrica.}$$

Esta expresión se obtiene también utilizando los cambios de variables utilizados por Fisher. La ventaja de utilizar esta fórmula para la densidad es que la serie converge más rápidamente que en la expresión que dimos en el teorema anterior.

La distribución acumulada de r, es decir $F_r(r \leq r^*) = F(r^* | N, p)$ ha sido tabulada por F.N. David (1938) para $p=0.9$ en incrementos de .1, $N=3(1)25, 50, 100, 200, 400$ y $r^*=-1(.05)1$. Dada la simetría de la densidad para $r \leq p$, tenemos que $F(r^* | N, p) = 1 - F(-r^* | N, -p)$. Veamos el uso de las tablas en algunos procedimientos estadísticos, de los que nos ocuparemos a continuación.

a) Consideremos el problema de contrastar la hipótesis

$$H_0: p = p_0$$

a partir de una muestra determinada.

Si la alternativa es del tipo $H_1: p > p_0$, rechazaremos H_0 si el coeficiente de correlación muestral r es tal que supera a r_0 , donde r_0 lo elegimos de manera que $1 - F(r_0 | N, p_0) = \alpha$, nivel de significación.

Si la alternativa es de la forma $H_1: p < p_0$, rechazaremos para $r_{ij} < r'_0$ un r'_0 tal que

$F(r'_0 | N, p_0) = \alpha$. Para $H_1: p \neq p_0$, la zona de rechazo viene dada por $r_{ij} < r'_1$ y $r_{ij} > r_1$ donde r_1 y r'_1 son tales que $F(r'_1 | N, p_0) + (1 - F(r_1 | N, p_0)) = \alpha$. David sugiere que r_1 y r'_1 sean elegidos de manera que ambas zonas tengan la misma probabilidad igual a $\frac{1}{2}\alpha$. Demostro en 1937 que para $N \geq 10$ y $|p| \leq 0.8$ la región crítica es similar a la región de un test univariante de H_0 , es decir, un test cuya función de potencia tiene su mínimo en p_0 .

Debemos también recordar que un quízico test basado en r es invariante bajo transformaciones del tipo $x_i^* = c_i x_i + d_i$ ($i=1, \dots, N$, $c_i \neq 0$, $d_i > 0$), que r es el invariante único de los estadísticos suficiente (lo que significa que cualquier otro test invariante puede expresarse como función de r). El procedimiento anterior para contrastar la hipótesis $H_0: p = p_0$ frente a alternativas del tipo $p > p_0$ es uniformemente más potente frente a todos los test invariante.

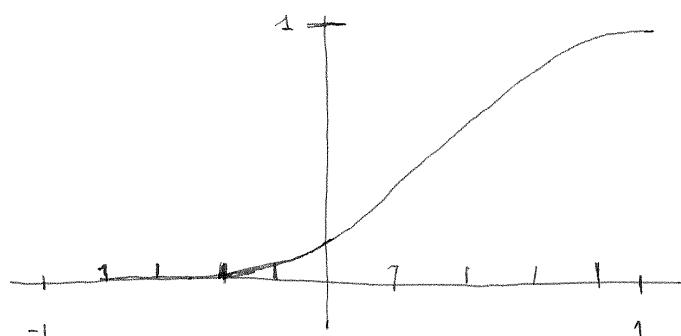
Como de ejemplo, impongamos que deseamos contrastar la hipótesis $H_0: p = 0.5$ frente a la alternativa $p \neq 0.5$ a un nivel $\alpha = 5\%$ utilizando una correlación muestral obtenida a partir de una muestra de tamaño 15. En las tablas de David encontramos (por interpolación) $F(0.027 | 15, 0.5) = 0.025$ y $F(0.805 | 15, 0.5) = 0.975$. Por tanto rechazaremos la hipótesis si r , en muestra muestra, es menor que 0.027 o mayor que 0.805.

b) Podemos utilizar las tablas de David para calcular la función de potencia de un test de medición. Si la región de rechazo de H_0 es $r > r_1$ y $r < r'_1$, la potencia del test es una función de la verdadera correlación p , $[1 - F(r_1 | N, p)] + [F(r'_1 | N, p)]$; es decir la probabilidad de rechazar la hipótesis nula cuando la correlación poblacional es p .

Consideremos, por ejemplo la función de potencia del test para $p = 0.5$ que obtenemos en el parágrafo anterior. La región de rechazo (unilateral) es $r \geq 0.5494$ para $\alpha = 5\%$. Las probabilidades de rechazo son:

p	-1.0	-0.8	-0.6	-0.4	-0.2	0	0.2	0.4	0.6	0.8	1
pots	0.0000	0.0000	0.0004	0.0032	0.0147	0.0500	0.1376	0.3215	0.6235	0.9279	1.0000

que gráficamente da lugar a la siguiente representación



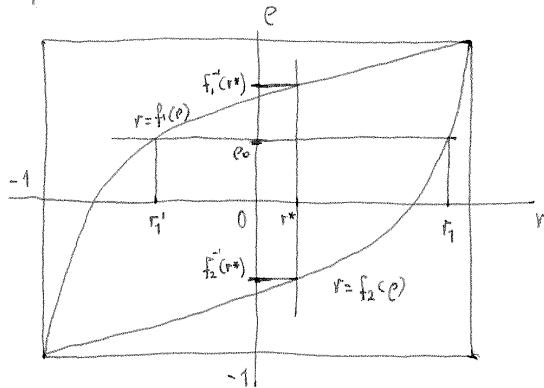
- c) Los cálculos de David proporcionan también reglas de confianza para ρ . Para N datos, r_1^* y r_2^* , los dos puntos de significación con funciones de ρ , a saber $f_1(\rho)$, $f_2(\rho)$ respectivamente, de manera que

$$\Pr \{ f_1(\rho) < r < f_2(\rho) | \rho \} = 1-\alpha$$

Las funciones $f_1(\rho)$ y $f_2(\rho)$ son funciones monótonas crecientes en ρ si r_1^* , r_2^* se eligen de manera que $1-F(r_1^*|N,\rho) = \frac{1}{2}\alpha = F(r_2^*|N,\rho)$. Si $\rho = f_i^{-1}(r)$ es la inversa de $r = f_i(\rho)$, $i=1,2$ entonces la desigualdad $f_i(\rho) < r$ es equivalente a $\rho < f_i^{-1}(r)$ y $r < f_i(\rho)$ es equivalente a $f_i^{-1}(r) < \rho$. De esta forma la anterior probabilidad puede escribirse

$$\Pr \{ f_2^{-1}(r) < \rho < f_1^{-1}(r) | \rho \} = 1-\alpha$$

Es decir la probabilidad de extraer una muestra y obtener un r de manera que el intervalo de extremos $[f_2^{-1}(r), f_1^{-1}(r)]$ cubra a ρ es precisamente $1-\alpha$. Se trata pues de un intervalo de confianza para ρ con nivel de confianza $1-\alpha$. Para todos de N y α dados



Las curvas $r = f_1(\rho)$ y $r = f_2(\rho)$ tienen el aspecto de la figura. Cuando entre tanto $H_0: \rho = \rho_0$, la intersección de la línea $\rho = \rho_0$ con las dos curvas dadas determina r_1^* , r_2^* de manera que el nivel sea fijo. Si queremos determinar una región de confianza para ρ sobre la base de r^* , coeficiente de correlación muestral, intersectaremos las curvas anteriores con $r = r^*$ y determinaremos los extremos del intervalo correspondiente. David proporciona estas curvas para $\alpha = 0.1, 0.05, 0.02$ y 0.01 y para varias N . Para el caso de test o regiones unilaterales utilizaremos tanto una desigualdad de los anteriores.

También es posible el uso de $F(r|N,\rho)$ para determinar intervalos de confianza. Dado r^* , $f_1^{-1}(r^*)$ es el valor de ρ que hace que $F(r^*|N,\rho) = \frac{1}{2}\alpha$ y análogamente $f_2^{-1}(r^*)$ es aquel valor de ρ para el cual $1-F(r^*|N,\rho) = \frac{1}{2}\alpha$.

Por ejemplo, un intervalo de confianza con $1-\alpha=0.95$ basado en un $r^*=0.792$ obtenido a partir de una muestra de tamaño 10. Utilizando la tabla II de David encontramos como límites del intervalo 0.34 y 0.94

Criterio de verosimilitud

Es interesante encontrar el intervalo de verosimilitud para contrastar $H_0: \rho = \rho_0$ a partir de una muestra X_1, \dots, X_N de una $N(\mu, \Sigma)$ con $\mu = (\mu_1, \mu_2)$ y $\Sigma = \Sigma_{11} = \sigma_1^2, \Sigma_{12} = \rho \sigma_1 \sigma_2, \Sigma_{21} = \rho \sigma_1 \sigma_2$ y $\Sigma_{22} = \sigma_2^2$. La función de verosimilitud

8

$$K \tilde{\sigma}_1^{-N} \tilde{\sigma}_2^{-N} (1-\rho^2)^{-N/2} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{a_1}{\sigma_1^2} - 2\rho \frac{a_{12}}{\sigma_1 \sigma_2} + \frac{a_{22}}{\sigma_2^2} + N \frac{(\bar{x}_1 - \mu_1)(\bar{x}_2 - \mu_2)}{\sigma_1 \sigma_2} + N \frac{(\bar{x}_1 - \mu_1)^2}{\sigma_1^2} \right] \right\}$$

Si maximizamos la anterior expresión ~~para~~ cuando los parámetros varían en \mathbb{R}^2 (en las restricciones $\sigma_1^2 > 0, \sigma_2^2 > 0, \rho^2 < 1$) obtenemos $\hat{\sigma}_{12}^2 = a_{12}/N$, $\hat{\sigma}_{11}^2 = a_{11}/N$, $\hat{\sigma}_{22}^2 = a_{22}/N$, $\hat{\mu}_{1,2} = \bar{x}_1$, $\hat{\mu}_{1,2} = \bar{x}_2$,

Si maximizamos en $w \in \Omega$ (se restringido para $\rho = \rho_0$) $\hat{\mu}_{1w} = \bar{x}_1 \Rightarrow \hat{\mu}_{2w} = \bar{x}_2$ pues la forma cuadrática de $\bar{x}_1 - \mu_1$ y $\bar{x}_2 - \mu_2$ en el exponente es definida negativa (alcanza por tanto su máximo cuando vale 0). Para maximizar el resto tenemos los siguientes, tendremos

$$\log k - N \log \delta_1 - N \log \delta_2 - \frac{1}{2} N \log (1 - \rho_0^2) - \frac{1}{2(1-\rho_0^2)} \left(\frac{a_{11}}{\delta_{1w}^2} - 2\rho_0 \frac{a_{11}}{\delta_1 \delta_2} + \frac{a_{22}}{\delta_{2w}^2} \right)$$

Derrivando respecto de δ_i , $i=1,2$ e igualando a 0, tendremos

$$-\frac{N}{\hat{\delta}_{iw}} - \frac{1}{2(1-\rho_0^2)} \left(-2 \frac{a_{ii}}{\hat{\delta}_{iw}^3} + 2\rho_0 \frac{a_{ij}}{\hat{\delta}_{iw}^2 \hat{\delta}_{jw}} \right) = 0 \quad , i \neq j, i, j = 1, 2$$

Esto es

$$\frac{a_{ii}}{\hat{\delta}_{iw}^2} - \rho_0 \frac{a_{ij}}{\hat{\delta}_{iw} \hat{\delta}_{jw}} = N(1 - \rho_0^2)$$

Sumando para $i=1, j=2$ y $j=1, i=2$, tenemos

$$\frac{a_{11}}{\hat{\delta}_{1w}^2} - 2\rho_0 \frac{a_{12}}{\hat{\delta}_{1w} \hat{\delta}_{2w}} + \frac{a_{22}}{\hat{\delta}_{2w}^2} = 2N(1 - \rho_0^2).$$

Restando para $i=1, j=2$ e $i=2, j=1$, tenemos

$$\frac{a_{11}}{\hat{\delta}_{1w}^2} = \frac{a_{22}}{\hat{\delta}_{2w}^2} = \frac{a^2}{\hat{\delta}^2}. \text{ Entonces}$$

$$\frac{a^2}{\hat{\delta}^2} - \frac{\rho_0 r a^2}{\hat{\delta}^2} = N(1 - \rho_0^2)$$

Así pues

$$\frac{N(1 - \rho_0^2)}{1 - \rho_0 r} = \frac{a^2}{\hat{\delta}^2} = \frac{\sqrt{a_{11} a_{22}}}{\hat{\delta}_{1w} \hat{\delta}_{2w}}$$

Y

$$\left| \hat{\sum}_w \right| = (1 - \rho_0^2) \hat{\delta}_{1w}^2 \hat{\delta}_{2w}^2 = \frac{(1 - \rho_0 r)^2}{1 - \rho_0^2} \cdot \frac{a_{11}}{N} \cdot \frac{a_{22}}{N}.$$

Lo mismo para máximos para $w \in \Omega$, con

$$\max_w L = \frac{(1 - \rho_0^2)^{\frac{1}{2}N} N^N}{(2\pi)^N (1 - \rho_0 r)^N a_{11}^{\frac{1}{2}N} a_{22}^{\frac{1}{2}N}} e^{-N}$$

$$\max_{\Omega} L = \frac{N^N}{(2\pi)^N (1 - r^2)^{\frac{1}{2}N} a_{11}^{\frac{1}{2}N} a_{22}^{\frac{1}{2}N}} e^{-N}$$

El criterio de la razón de verosimilitud es por tanto

$$\frac{\max_w L}{\max_{\Omega} L} = \frac{(1 - \rho_0^2)^{\frac{1}{2}N} (1 - r^2)^{\frac{1}{2}N}}{(1 - \rho_0 r)^N} = \left[\frac{(1 - \rho_0^2)(1 - r^2)}{(1 - \rho_0 r)^2} \right]^{\frac{1}{2}N}$$

El test correspondiente es $(1-p_0^2)(1-r^2)(1-p_0r)^{-2} \leq c$, donde c redige de manera que la probabilidad de la desigualdad, cuando H_0 es cierta se extrae de probabilidad marginal bivariante con $p=p_0$, sea el nivel de significación elegido. La regla crítica puede también presentarse

$$(p_0^2c - p_0^2 + 1)r^2 - 2p_0cr + c - 1 + p_0^2 \geq 0,$$

o bien

$$r > \frac{p_0c + (1-p_0^2)\sqrt{1-c}}{p_0^2c + 1 - p_0^2}, \quad r < \frac{p_0c - (1-p_0^2)\sqrt{1-c}}{p_0^2c + 1 - p_0^2}$$

Así, el test de la varianza de variancia de $H_0: p=p_0$ frente a la alternativa $H_1: p \neq p_0$ tiene una regla crítica de la forma $r > r_1$ y $r < r_1'$, pero r_1 y r_1' no están elegidos de manera que la probabilidad de la desigualdad sea $\frac{1}{2}\alpha$ cuando H_0 es cierta, sino de la forma deseada en las dos últimas desigualdades y un c teniendo el significado anterior (la probabilidad de ambas desigualdades igual a α).

La distribución asintótica de un coeficiente de correlación muestral y de la Z de Fisher

Se trata de demostrar en este apartado que a medida que aumenta el tamaño de la muestra la distribución del coeficiente de correlación muestral tiende a la normal. La distribución de una función particular de la correlación muestral, conocida como la Z de Fisher (descubierta por Fisher en 1921), cuya varianza es aproximadamente independiente de la correlación poblacional, tiende más rápidamente a la normal. En primer lugar demostraremos un teorema central del límite para variables m-dimensionalas.

TEOREMA. - Sean y_1, y_2, \dots vectores m-dimensionales independientes e idénticamente distribuidos con medias $E(y_\alpha) = v$ y covarianzas $E[(y_\alpha - v)(y_\alpha - v)'] = T$. Entonces la distribución límite de $(\sqrt{n}) \sum_{\alpha=1}^n (y_\alpha - v)$ cuando $n \rightarrow \infty$ es $N(0, T)$.

Demonstración. - Sea

$$\phi_n(t, u) = E \left(\exp \left[iut' \frac{1}{\sqrt{n}} \sum_{\alpha=1}^n (y_\alpha - v) \right] \right),$$

donde u es un escalar y t un vector de m -componentes. Para valores de t fijos, $\phi_n(t, u)$ pueden considerarse como la función característica de $(\sqrt{n}) \sum_{\alpha=1}^n (t'y_\alpha - E(t'y_\alpha))$. Por el teorema central del límite (para variables unidimensionales), la distribución límite correspondiente será $N(0, t'Tt)$. Por tanto

$$\lim_{n \rightarrow \infty} \phi_n(t, u) = e^{-\frac{1}{2}u^2 t'Tt}, \quad \forall u, t$$

Entonces teniendo $u=1$, tenemos

$$\lim_{n \rightarrow \infty} E \left[\exp \left(it' \frac{1}{\sqrt{n}} \sum_{\alpha=1}^n (y_\alpha - v) \right) \right] = e^{-\frac{1}{2}t'Tt}, \quad \forall t$$

Como $e^{-\frac{1}{2}t'Tt}$ es continua para $t=0$, la convergencia uniforme en algún entorno de cero. El teorema al cumplir.

Hacemos a demostrar a continuación que la distribución asintótica de la matriz de covarianzas muestral es normal.

TEOREMA. - Sea $A(n) = \sum_{\alpha=1}^n (\bar{x}_\alpha - \bar{\bar{x}})(\bar{x}_\alpha - \bar{\bar{x}})'$, donde \bar{x}_1, \dots son todas independientes y $N(\mu, \Sigma)$ y $n=N-1$. Entonces la distribución asintótica de $B(n) = (\sqrt{n}) [A(n) - n\Sigma]$ es normal con media 0 y covarianzas

$$E(b_{ij}(n)b_{kl}(n)) = \delta_{ik}\delta_{jl} + \delta_{il}\delta_{jk}.$$

Demonstración. - Como demostramos anteriormente $A(n)$ se distribuye como $A(n) = \sum_{\alpha=1}^n Z_\alpha Z_\alpha'$, donde Z_1, Z_2, \dots se distribuyen $N(0, \Sigma)$ e independientes. Podemos expresar los elementos de $Z_\alpha Z_\alpha'$ de forma vectorial como sigue

$$Y_\alpha' = [Z_{1\alpha}^2, Z_{1\alpha}Z_{2\alpha}, \dots, Z_{2\alpha}^2, \dots, Z_{p\alpha}^2]$$

los momentos γ_{ik} pueden deducirse de los momentos de Z_{ik} tal como se obtienen en el momento 3 (6).
 Tenemos $E(Z_{ia}Z_{ja}) = \sigma_{ij}$, $E(Z_{ia}Z_{ja}Z_{ka}Z_{la}) = \sigma_{ij}\sigma_{kl} + \sigma_{ik}\sigma_{jl} + \sigma_{il}\sigma_{kj}$, $E[(Z_{ia}Z_{ja}-\sigma_{ij})(Z_{ka}Z_{la}-\sigma_{kl})] = \sigma_{ik}\sigma_{jl} + \sigma_{il}\sigma_{kj}$ (se han obtenido mediante la función característica). Así, los vectores γ_{ik} satisfacen las condiciones del teorema anterior siendo los elementos de V los elementos de Σ anejados de forma similar a como los hemos hecho con γ_{ik} y los elementos de T los que acabamos de obtener. Si los otros elementos de $A(n)$ los anejamos también en forma rectangular, $W(n)$, entonces $W(n) - nV = \sum_{k=1}^n (\gamma_{ik} - V)$. Aplicando ahora el teorema anterior $[W(n) - nV]$ se distribuye asintóticamente normal con media 0 y la matriz de covarianzas la de γ_{ik} .

Estamos particularmente interesados en la correlación muestral

$$r(n) = \frac{A_{ij}(n)}{\sqrt{A_{ii}(n) A_{jj}(n)}} \quad , \quad i \neq j$$

Esto puede también escribirse de la forma

$$r(n) = \frac{c_{ij}(n)}{\sqrt{c_{ii}(n) c_{jj}(n)}}$$

donde $c_{gh}(n) = A_{gh}(n)/\sqrt{\lambda_{gg} \lambda_{hh}}$. El conjunto $c_{ii}(n)$, $c_{jj}(n)$ y $c_{ij}(n)$ se distribuye como

$$\sum_{k=1}^n \begin{pmatrix} Z_{ik}^* \\ Z_{jk}^* \end{pmatrix} (Z_{ik}^* Z_{jk}^*) = \sum_{k=1}^n \begin{pmatrix} Z_{ik}/\sqrt{\sigma_{kk}} \\ Z_{jk}/\sqrt{\sigma_{jj}} \end{pmatrix} (Z_{ik}/\sqrt{\sigma_{kk}}, Z_{jk}/\sqrt{\sigma_{jj}})$$

donde (Z_{ik}^*, Z_{jk}^*) son independientes, cada una con distribución $N\left[\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}\right]$ y $\rho = \sigma_{ij}/\sqrt{\sigma_{ii}\sigma_{jj}}$. Sean

$$U(n) = \frac{1}{n} \begin{pmatrix} c_{ii}(n) \\ c_{jj}(n) \\ c_{ij}(n) \end{pmatrix} \quad y \quad b = \begin{pmatrix} 1 \\ 1 \\ \rho \end{pmatrix}$$

Entonces $\sqrt{n}(U(n) - b)$ se distribuye asintóticamente normal con media 0 y matriz de covarianzas

$$\begin{pmatrix} 2 & 2\rho^2 & 2\rho \\ 2\rho^2 & 2 & 2\rho \\ 2\rho & 2\rho & 1+\rho^2 \end{pmatrix}$$

Resistimos ahora el siguiente teorema general

TEOREMA .- Sea $U(n)$ un vector con m componentes y b un vector fijo. Supongamos que $\sqrt{n}(U(n) - b)$ se distribuye asintóticamente $N(0, T)$. Sea $W = f(U)$ una función de un vector U cuyas primera y segunda derivadas existen en un entorno de $U=b$. Sea $\frac{\partial f(u)}{\partial u_i} \Big|_{u=b}$ la i -ésima componente de ϕ_b . entonces la distribución límite de $\sqrt{n}(f(U(n)) - f(b))$ es $N(0, \phi_b^T T \phi_b)$.

La demostración del teorema puede consultarse en el texto de Cramér.

Después de $U(n)$ ante definido, con b y T los correspondientes valores ante introducir, satisface las condiciones del teorema. La función

$$V = \frac{U_3}{\sqrt{U_1 U_2}} = U_3 U_1^{-1/2} U_2^{-1/2}$$

satisface las condiciones de semi-variabilidad exigidas. Los elementos de ϕ_b son

$$\frac{\partial V}{\partial u_1} \Big|_{u=b} = -\frac{1}{2} U_3 U_1^{-3/2} U_2^{-1/2} \Big|_{u=b} = -\frac{1}{2} \rho, \quad \frac{\partial V}{\partial u_2} \Big|_{u=b} = -\frac{1}{2} U_3 U_1^{-1/2} U_2^{-3/2} \Big|_{u=b} = -\frac{1}{2} \rho, \quad \frac{\partial V}{\partial u_3} \Big|_{u=b} = U_1^{-1/2} U_2^{-1/2} \Big|_{u=b} = 1$$

$f(p) = p$. La varianza asintótica de $\sqrt{n}(r(n) - p)$ es

$$\left(-\frac{1}{2}p, -\frac{1}{2}p, 1\right) \begin{pmatrix} 2 & 2p^2 & 2p \\ 2p & 2 & 2p \\ 2p & 2p & 1-p^2 \end{pmatrix} \begin{pmatrix} -\frac{1}{2}p \\ -\frac{1}{2}p \\ 1 \end{pmatrix} = (p-p^3, p-p^3, 1-p^2) \begin{pmatrix} -\frac{1}{2}p \\ -\frac{1}{2}p \\ 1 \end{pmatrix} = 1-2p^2+p^4 = (1-p^2)^2.$$

Hemos obtenido el siguiente teorema:

TEOREMA .- Si $r(n)$ es el coeficiente de correlación muestral de una muestra de tamaño $N=(n+1)$ de una distribución normal con correlación p , entonces $\sqrt{n}(r(n)-p)/(1-p^2)$ [o $\sqrt{N}(r(n)-p)/(1-p^2)$] se distribuye asintóticamente $N(0,1)$.

Apoyándonos en el teorema anterior, si $f(x)$ es una función con primera y segunda derivadas en $x=p$, entonces $\sqrt{n}(f(r) - f(p))$ también es asintóticamente normal con media 0 y varianza $\left(\frac{df}{dx}\Big|_{x=p}\right)^2(1-p^2)^2$.

Es usual considerar f una función cuya varianza asintótica sea constante (la unidad) independiente del parámetro p . Una función de este tipo sería la logaritmo

$$f'(p) = \frac{1}{1-p^2} = \frac{1}{2} \left(\frac{1}{1+p} + \frac{1}{1-p} \right)$$

Podemos tomar $f(p) = \frac{1}{2} [\log(1+p) - \log(1-p)] = \frac{1}{2} \log \left[\frac{1+p}{1-p} \right]$. La llamada z de Fisher es

$$z = \frac{1}{2} \log \frac{1+r}{1-r} \quad \text{y sea} \quad \xi = \frac{1}{2} \log \frac{1+r}{1-r}.$$

TEOREMA .- Sea z definida como ante, donde r es el coeficiente de correlación muestral de una muestra de tamaño $N=n+1$, de una normal bivariante con correlación p , sea ξ el valor ante definido. Entonces $\sqrt{n}(z-\xi)$ es asintóticamente normal con media 0 y varianza 1.

Se puede demostrar que aproximadamente

$$E(z) \approx \xi + \frac{p}{2n} \quad E(z-\xi)^2 \approx \frac{1}{n-2} \approx E(z-\xi - \frac{p}{2n})^2$$

Esta última aproximación se sigue de la expresión

$$E(z-\xi)^2 = \frac{1}{n} + \frac{8-p^2}{4n^2} + \dots$$

Es muy buena para valores de p^2/n^2 pequeños. Netteling (1953) estudió los momentos de z hasta el orden n^{-3} . Una importante propiedad de la z de Fisher es que su aproximación a la normal es mucho más rápida que para F. David (1938) estableció comparaciones entre las probabilidades tabuladas y las probabilidades obtenidas suponiendo que z se distribuía normalmente. Recomendó que para $N > 25$ se tome z como distribuida normalmente con media y varianza las dadas anteriormente.

Antes de finalizar con los coeficientes de correlación daremos algunas pautas para la utilización de la z de Fisher.

a) Supongamos que deseamos contrastar la hipótesis $p=p_0$ sobre la base de una muestra de tamaño N frente a la alternativa $p \neq p_0$. Calcularemos r y después z . Sea

$$\xi_0 = \frac{1}{2} \log \frac{1+p_0}{1-p_0}$$

La región de rechazo al 5% vendrá dada por

$$\sqrt{N-3} |z - \xi_0| > 1.96$$

Una región mejor es

$$\sqrt{N-3} |z - \xi_0 - \frac{1}{2} p_0/(N-1)| > 1.96$$

- b) Supongamos que tenemos una muestra de tamaño N_1 de una población que genera muestra N_2 de otra población. Como contrastar la hipótesis de que los dos coeficientes de correlación son iguales, $\rho_1 = \rho_2$? Del teorema de la Z de Fisher sabemos que si la hipótesis nula es cierta Z_1, Z_2 son asintóticamente normales con media 0 y varianza $\frac{1}{(N_1-3)} + \frac{1}{(N_2-3)}$. Como regla crítica al 5%, utilizaremos

$$\frac{|Z_1 - Z_2|}{\sqrt{\frac{1}{(N_1-3)} + \frac{1}{(N_2-3)}}} > 1.96$$

- c) Bajo las condiciones del apartado anterior supongamos que $\rho_1 = \rho_2 = \rho$. Como utilizar los resultados de ambas muestras para estimar conjuntamente ρ ? Puesto que Z_1, Z_2 tienen varianzas $\frac{1}{(N_1-3)} + \frac{1}{(N_2-3)}$ respectivamente, podemos estimar ρ mediante

$$\frac{(N_1-3)Z_1 + (N_2-3)Z_2}{N_1 + N_2 - 6}$$

y convertir esto en un estimador de ρ mediante la transformación inversa de la Z.

- d) Sea r el coeficiente de correlación muestral de N observaciones. Como obtener un intervalo de confianza para ρ ? Sabemos que aproximadamente

$$\Pr \left\{ -1.96 < \sqrt{N-3} (Z - \bar{r}) < 1.96 \right\} = 0.95$$

De aquí deducimos que $[-1.96/\sqrt{N-3} + \bar{r}, 1.96/\sqrt{N-3} + \bar{r}]$ es un intervalo de confianza para ρ . A partir de aquí obtenemos la regla para ρ utilizando la transformación inversa $\rho = \tanh^{-1} r = (\bar{r}^2 - \bar{e}^{-2}) / (\bar{r}^2 + \bar{e}^{-2})$ que es una transformación monótona. La regla es

$$\tanh \left(\bar{r} - 1.96/\sqrt{N-3} \right) < \rho < \tanh \left(\bar{r} + 1.96/\sqrt{N-3} \right).$$

3. COEFICIENTES DE CORRELACIONES PARCIALES

Recordemos que los coeficientes son coeficientes de correlación en distribuciones condicionales. Siendo más concretamente si \mathbf{x} se distribuye $N(\mu, \Sigma)$ la distribución condicional del subvector $\mathbf{x}^{(1)}$ dado $\mathbf{x}^{(2)} = \mathbf{x}^{(2)}$, viene dada por $N(\mu^{(1)} + \beta(\mathbf{x}^{(2)} - \mu^{(2)}), \Sigma_{11.2})$, donde

$$\begin{aligned}\beta &= \Sigma_{12} \Sigma_{22}^{-1} \\ \Sigma_{11.2} &= \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21}\end{aligned}$$

Las correlaciones parciales de $\mathbf{x}^{(1)}$ dado $\mathbf{x}^{(2)}$ son las covarianzas, calculadas de la forma ya establecida, a partir de $\Sigma_{11.2}$. Tenemos como llevar a cabo la estimación de estos valores y, como, a partir de ellos, podemos efectuar contrastes de hipótesis.

En primer lugar nos vamos a ocupar del problema de la estimación. Supongamos que tenemos una muestra de tamaño N de una normal $N(\mu, \Sigma)$. Cuál sería la estimación máxima-verosímil de los correlaciones parciales de $\mathbf{x}^{(1)}$, $\hat{\rho}_{ij}, q_{ij}, -n, p$? Sabemos que la estimación máxima-verosímil de Σ es

$$\hat{\Sigma} = \frac{1}{N} \sum_{\alpha=1}^N (\mathbf{x}_\alpha - \bar{\mathbf{x}})(\mathbf{x}_\alpha - \bar{\mathbf{x}})', \text{ con } \bar{\mathbf{x}} = \frac{1}{N} \sum_{\alpha=1}^N \mathbf{x}_\alpha.$$

La correspondencia entre Σ y $\Sigma_{11.2}$ y β y Σ_{22} es más o menos en virtud de las relaciones (definiciones) anteriores, de

$$\begin{aligned}\hat{\Sigma}_{12} &= \beta \hat{\Sigma}_{22} \\ \hat{\Sigma}_{11} &= \hat{\Sigma}_{11.2} + \beta \hat{\Sigma}_{22}'\end{aligned}$$

pues tanto, teniendo en cuenta una propiedad de los estimadores máximos-verosímiles podemos afirmar que los correspondientes estimadores de $\Sigma_{11.2}$ y β y Σ_{22} vendrán dados por $\hat{\Sigma}_{11.2} = \hat{\Sigma}_{11} - \hat{\Sigma}_{12} \hat{\Sigma}_{22}^{-1} \hat{\Sigma}_{21}$, $\hat{\beta} = \hat{\Sigma}_{12} \hat{\Sigma}_{22}^{-1}$, $\hat{\Sigma}_{22}$. Además las estimaciones de los coeficientes de correlación parcial serían:

$$\hat{c}_{ij, q+1, \dots, p} = \frac{\hat{b}_{ij, q+1, \dots, p}}{\sqrt{\hat{b}_{ii, q+1, \dots, p} \hat{b}_{jj, q+1, \dots, p}}} \quad i, j = 1, \dots, q$$

Donde $\hat{b}_{ij, q+1, \dots, p}$ es el i, j -ésimo elemento de $\hat{B}_{11,2}$.

TEOREMA. - Sea x_1, \dots, x_N una muestra de tamaño N de una $N(p, \Sigma)$. Los estimadores máximos-verosímiles de $c_{ij, q+1, \dots, p}$, covarianzas parciales de los primeros q componentes condicionadas a los $p-q$ restantes, vienen dadas por

$$\hat{c}_{ij, q+1, \dots, p} = \frac{a_{ij, q+1, \dots, p}}{\sqrt{a_{ii, q+1, \dots, p} a_{jj, q+1, \dots, p}}}$$

donde

$$(a_{ij, q+1, \dots, p}) = A_{11} - A_{12} A_{22}^{-1} A_{21} \quad ,$$

$$\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} = A = \sum_{\alpha=1}^N (x_\alpha - \bar{x})(x_\alpha - \bar{x})'$$

la estimación $\hat{b}_{ij, q+1, \dots, p}$, que denotaremos por $b_{ij, q+1, \dots, p}$ es conocida como el coeficiente de covariación marginal entre X_i y X_j cuando X_{q+1}, \dots, X_p permanecen constantes.

Las interpretaciones geométricas pueden darse para estos resultados. A saber:

- a) En un espacio p -dimensional consideremos los N puntos x_1, \dots, x_N , tales muestras. La función de regresión

$$x^{(i)} = \bar{x}^{(i)} + \hat{\beta} (x^{(i)} - \bar{x}^{(i)})$$

es un hiperplano $p-q$ -dimensional que resulta de la intersección de los q hiperplanos $p-1$ -dimensionales

$$x_i = \bar{x}_i + \left[\sum_{j=q+1}^p \hat{\beta}_{ij} (x_j - \bar{x}_j) \right] \quad , \quad i = 1, \dots, q$$

Aquí $\hat{\beta}_{ij}$ es un elemento de $\hat{\beta} = \hat{B}_{12} \hat{B}_{22}^{-1} = A_{12} A_{22}^{-1}$. La i -ésima fila de $\hat{\beta}$ es $[\hat{\beta}_{1q+1}, \dots, \hat{\beta}_{pq}]$. La parte derecha de la anterior igualdad es la función de regresión mínimos-cuadráticos de x_i sobre x_{q+1}, \dots, x_p ; es decir, si proyectamos los puntos x_1, \dots, x_N en el hiperplano de las coordenadas x_1, x_{q+1}, \dots, x_p , entonces la expresión anterior es el plano de regresión. El punto de coordenadas

$$x_i = \bar{x}_i + \sum_{j=q+1}^p \hat{\beta}_{ij} (x_j - \bar{x}_j) \quad , \quad i = 1, \dots, q$$

$$x_j = x_{j|x} \quad , \quad j = q+1, \dots, p$$

está en el hiperplano anterior. La diferencia entre la i-ésima coordenada de x_α y el punto anterior $\Rightarrow y_{i|x} = x_{i|x} - [\bar{x}_i + \sum_{j=q+1}^p \hat{\beta}_{ij} (x_{j|x} - \bar{x}_j)]$ para $i = 1, \dots, q \neq 0$ para las otras coordenadas. Pongamos

$$y_\alpha = \begin{bmatrix} y_{1|x} \\ \vdots \\ y_{q|x} \end{bmatrix}.$$

Estos puntos pueden representarse como N puntos en un espacio q -dimensional. Entonces $A_{11,2} = \sum_{\alpha=1}^N y_\alpha y_\alpha'$.

- b) Podemos, por otra parte, interpretar la muestra como p puntos en un espacio N -dimensional. Sean $z_j = (x_{j1}, \dots, x_{jN})$ el j -ésimo punto (las j -ésimas coordenadas de la muestra), y hagamos $z_{p+1} = (1, \dots, 1)$ para el $p+1$ -ésimo punto. El punto de coordenadas $\bar{x}_1, \dots, \bar{x}_i$ es $\bar{x}_i z_{p+1}$. La proyección de z_i sobre el hiperplano definido mediante z_{q+1}, \dots, z_{p+1} es

$$z_i^* = \bar{x}_i z_{p+1} + \sum_{j=q+1}^p \hat{\beta}_{ij} (z_j - \bar{x}_j z_{p+1})$$

y sea punto del hipoplano cuya distancia a \tilde{z}_i es mínima. Sea \tilde{z}_j el vector de \tilde{z}_i a \tilde{z}_i , 3 (8) decir $\tilde{z}_i - \tilde{z}_j$, o mejor en equivalente tratado de manera que permanezca constante el origen de coordenadas. El conjunto de vectores $\tilde{z}_i - \tilde{z}_j$ son las proyecciones de $\tilde{z}_i - \tilde{z}_j$ en el hipoplano ortogonal a $\tilde{z}_{p+1}, \dots, \tilde{z}_p$. Entonces $\tilde{z}_i \cdot \tilde{z}_j = \text{dist. } \tilde{z}_i \cdot \tilde{z}_j$ es el cuadrado de la longitud de \tilde{z}_i , o lo que es lo mismo, el cuadrado de la distancia de \tilde{z}_i a \tilde{z}_j . Así $\tilde{z}_i \cdot \tilde{z}_j / \sqrt{\tilde{z}_i \cdot \tilde{z}_i} = \text{dist. } \tilde{z}_i \cdot \tilde{z}_j / \sqrt{\tilde{z}_i \cdot \tilde{z}_i}$ es el coseno del ángulo entre \tilde{z}_i y \tilde{z}_j .

Un ejemplo de coeficiente de correlación parcial.

Consideremos algunos datos [(Hoover, 1907) J. Roy. Stat. Soc. Vol 70, pp. 1-42] acerca de la cosecha de heno (X₁) en cincos de libras por acre, cantidad de lluvia caída durante la primavera (X₂) y temperaturas anormales superiores a 42° F en la primavera (X₃) para una determinada zona de Inglaterra durante un periodo de 20 años. Las estimaciones de μ_i , $\sigma_i = \sqrt{\hat{\sigma}_{ii}}$ y ρ_{ij} son

$$\hat{\mu} = \bar{x} = \begin{bmatrix} 28.02 \\ 4.91 \\ 594 \end{bmatrix}, \quad \begin{bmatrix} \hat{\sigma}_1 \\ \hat{\sigma}_2 \\ \hat{\sigma}_3 \end{bmatrix} = \begin{bmatrix} 4.42 \\ 1.10 \\ 85 \end{bmatrix}, \quad \begin{bmatrix} 1 & \hat{\rho}_{12} & \hat{\rho}_{13} \\ \hat{\rho}_{21} & 1 & \hat{\rho}_{23} \\ \hat{\rho}_{31} & \hat{\rho}_{32} & 1 \end{bmatrix} = \begin{bmatrix} 1.00 & 0.80 & -0.40 \\ 0.80 & 1.00 & -0.56 \\ -0.40 & -0.56 & 1.00 \end{bmatrix}$$

A partir de las correlaciones observamos que la cantidad de lluvia caída (X_2) y la cosecha (X_1) están relacionadas positivamente, cosecha y temperatura están negativamente al igual que lluvia y temperatura. Que interpretación puede darse a la relación negativa aparente que existe entre la cosecha y la temperatura? ¿Tienden las altas temperaturas a causar bajas cosechas o las altas temperaturas están asociadas con bajas cantidades de lluvia y por tanto con bajas cosechas? Para responder a estas cuestiones podemos considerar la correlación entre cosecha y temperatura cuando la cantidad de lluvia es constante; es decir, retira de utilizar los datos anteriores para estimar el coeficiente de correlación parcial entre X_1 y X_3 . El valor 1

$$\frac{\hat{\rho}_{32}}{\sqrt{\hat{\sigma}_{12} \cdot \hat{\sigma}_{32}}} = 0.097$$

Así, el efecto de la lluvia eliminado, cosecha y temperatura siguen relacionados positivamente. La relación sigue siendo fuerte, altas lluvias y altas temperaturas aumentan las cosechas de heno, pero en casi todos los años observados las grandes lluvias han venido con bajas temperaturas y viceversa.

La distribución del coeficiente de correlación parcial

Las correlaciones parciales se obtienen a partir de $A_{112} = A_{11} - A_{12}A_{22}^{-1}A_{12}$ de la misma forma mediante la que obtuvimos las correlaciones de A . Para obtener la distribución de las correlaciones demostraremos que A se distribuye como $\sum_{\alpha=1}^m Z_\alpha Z_\alpha'$ donde las Z_α son independientes y cada una de ellas $N(0, \Sigma)$. Ademas de forma similar $\sum_{\alpha=1}^{m-r} Z_\alpha Z_\alpha'$ donde las Z_α son independientes y $N(0, \Phi)$, además independientes de G .

Tercera: - Supongamos que Y_1, \dots, Y_m son independientes con Y_α distribuida como $N(\Gamma W_\alpha, \Phi)$, donde W_α es un vector de r componentes. Sea $G = [\alpha Y_\alpha W_\alpha^T H]$ donde $H = \sum_\alpha W_\alpha W_\alpha^T$ y es no singular. Entonces $\sum_{\alpha=1}^m Y_\alpha Y_\alpha^T - GHG^T$ se distribuye como $\sum_{\alpha=1}^{m-r} U_\alpha U_\alpha^T$, donde U_α son independientes y $N(0, \Phi)$, además independientes de G .

Demonstración: - Sea $W = (w_1, \dots, w_m)$ una $r \times m$ matriz cuadrada tal que $FHF^T = I$, entonces $F^T H^T F = I$. Sea $E_2 = FW$, entonces $W = E_2 F^T$. Así

$$E_2 E_2^T = FWW^T F = F \left[\sum_\alpha w_\alpha w_\alpha^T F^T \right] F = FHF^T = I.$$

Resulta que las filas de E_2 son vectores ortogonales. Señal que existiría una matriz E_3 $(m-r) \times m$ tal que $E^T = [E_1' \ E_2']$ sea ortogonal. Sea ahora $Y = (Y_1, \dots, Y_m) = WE$, o $U = YE^T$ (sabiendo, $U_\alpha = \sum_\beta \epsilon_{\alpha\beta} Y_\beta$). Aplicando un conocido teorema, las columnas de U , o decir U_α , son independientes y distribuidas normalmente, cada una de ellas con covarianza Φ . La media rendida daría por

$$E(U) = E(YE') = \Gamma W E' = \Gamma F^{-1} E_2 (E_1 E_2') = (\Gamma F^{-1} E_2 E_1' \quad \Gamma F^{-1} E_2 E_2') = (0 \quad \Gamma F^{-1})$$

Para completar la demostración necesitamos demostrar que

$$\sum_{\alpha=1}^{m-r} Y_\alpha Y_\alpha' - GHG' = \sum_{\alpha=1}^{m-r} U_\alpha U_\alpha'$$

Sabemos que $\sum_{\alpha=1}^m Y_\alpha Y_\alpha' = \sum_{\alpha=1}^m U_\alpha U_\alpha'$ por la transformación que pasa de uno a otro, ortogonal. También verifica

$$\begin{aligned} GHG' &= (Y W H^{-1}) H (H^{-1} W Y') = U E E_2' (F')' H^{-1} F^{-1} E_2 E_1' U' = U \begin{pmatrix} E_1' \\ E_2' \end{pmatrix} E_2' E_2 (E_1' E_2') U' = \\ &= U \begin{pmatrix} 0 \\ I \end{pmatrix} (0 I) U' = \sum_{\alpha=m-r+1}^m U_\alpha U_\alpha'. \end{aligned}$$

Así pues

$$\sum_{\alpha=1}^m Y_\alpha Y_\alpha' - GHG' = \sum_{\alpha=1}^m U_\alpha U_\alpha' - \sum_{\alpha=m-r+1}^m U_\alpha U_\alpha' = \sum_{\alpha=1}^{m-r} U_\alpha U_\alpha',$$

De los anteriores consideramos se sigue que si $\Gamma = 0$, $E(U) = 0$, obtenemos el siguiente corolario

COROLARIO - Si $\Gamma = 0$, la matriz GHG' del teorema anterior se distribuye como $\sum_{\alpha=1}^{m-r} U_\alpha U_\alpha'$ donde las U_α son independientes y distinguidas $N(0, \phi)$.

Podemos ahora encontrar la distribución de $A_{11.2}$ de la misma forma. Vemos que A se distribuye como $\sum_{k=1}^{N-1} Z_k Z_k'$, donde las Z_k son independientes, cada una $N(0, \Sigma)$. Si fraccionamos Z_k en dos matrices de dimensiones p y $p-q$ respectivamente,

$$Z_k = \begin{pmatrix} Z_k^{(1)} \\ Z_k^{(2)} \end{pmatrix}.$$

Entonces $A_{11} = \sum_{k=1}^{N-1} Z_k^{(1)} Z_k^{(1)'} = \sum_{k=1}^{N-1} Z_k^{(1)}$. La distribución condicional de $Z_1^{(1)} - Z_{N-1}^{(1)}$ dado $Z_1^{(1)} = z_1^{(1)}, \dots, Z_{N-1}^{(1)} = z_{N-1}^{(1)}$ es

$$\frac{\prod_{\alpha=1}^{N-1} n(z_\alpha | 0, \Sigma)}{\prod_{\alpha=1}^{N-1} n(z_\alpha^{(1)} | 0, \Sigma)} = \prod_{\alpha=1}^{N-1} \frac{n(z_\alpha | 0, \Sigma)}{n(z_\alpha^{(1)} | 0, \Sigma)} = \prod_{\alpha=1}^{N-1} n(z_\alpha^{(1)} | \beta z_\alpha^{(1)}, \Sigma_{11.2})$$

donde $\beta = \Sigma_{12} \Sigma_{22}^{-1}$ y $\Sigma_{11.2} = \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21}$. Aplicando ahora el teorema con $Z_\alpha^{(1)} = Y_\alpha$, $Z_\alpha^{(2)} = W_\alpha$, $N-1 = m$, $p-q = r$, $\beta = \Gamma$, $\Sigma_{11.2} = \phi$, $A_{11} = \sum Y_\alpha Y_\alpha'$, $A_{12} A_{21}' = G$, $A_{22} = H$. Vemos que la distribución condicional de $A_{11} - A_{12} A_{21}' A_{21} = A_{11} - (A_{12} A_{21}') A_{22} (A_{21}' A_{21}) = A_{11.2}$ dado $Z_k^{(1)} = z_k^{(1)}$ es la de $\sum_{\alpha=1}^{N-1-(p-q)} U_\alpha U_\alpha'$ donde las U_α son independientes, cada una una distribución $N(0, \Sigma_{11.2})$. Como esta distribución no depende de $\{z_k^{(1)}\}$ entonces obtenemos finalmente:

TEOREMA - La matriz $A_{11.2} = A_{11} - A_{12} A_{21}' A_{21}$ se distribuye como $\sum_{\alpha=1}^{N-1-(p-q)} U_\alpha U_\alpha'$, donde las U_α se distribuyen independientes, cada una una distribución $N(0, \Sigma_{11.2})$.

Como corolario obtenemos

COROLARIO - Si $\Sigma_{12} = 0$ ($\beta = 0$) entonces $A_{11.2}$ se distribuye como $\sum_{\alpha=1}^{N-(p-q)} U_\alpha U_\alpha'$ y $A_{12} A_{21}' A_{21}$ se distribuye como $\sum_{\alpha=N-(p-q)}^{N-1} U_\alpha U_\alpha'$ donde las U_α son independientes y $N(0, \Sigma_{11.2})$.

Se sigue de estos resultados que la distribución de $t_{N-p, q, 1-\alpha}$ basada en las N observaciones es la misma que la de un coeficiente de correlación ordinario basado en $N - (p-q)$ observaciones con el correspondiente coeficiente de correlación polivalente dado por $t_{N-p, q, 1-\alpha}$. Usaremos para probar el teorema

TEOREMA . - Si la función de distribución de r_{ij} basado en una muestra de tamaño N de una $N(0, \Sigma)$ con coeficiente de correlación polacial ρ_{ij} la denotamos por $F(r|N, \rho_{ij})$, entonces la función de distribución del coeficiente de correlación parcial muestral $r_{ij|q_1, \dots, i, p}$ basado en una muestra de tamaño N de la misma normal es $F(r|N-(p-q), \rho_{ij|q_1, \dots, i, p})$.

Esta función de distribución fue obtenida por Fisher en el año 1924.

Test de hipótesis y regresión de confianza para coeficiente de correlación parcial.

Puesto que la distribución de un coeficiente de correlación parcial $r_{ij|q_1, \dots, i, p}$ basado en una muestra de tamaño N de una distribución con correlación polacial $\rho_{ij|q_1, \dots, i, p}$ igual a cierto valor p , es la misma que la distribución de un coeficiente de correlación ordinario r basado en una muestra de tamaño $N-(p-q)$ de una distribución con el correspondiente coeficiente de correlación polacial p . Todos los procedimientos de inferencia estadística antes dadas pueden utilizarse ahora. Se actúa de forma semejante pero reemplazando N por $N-(p-q)$. Veamos dos ejemplos de esta actuación.

Ejemplo 1. Supongamos que sobre la base de una muestra de tamaño N deseamos obtener un intervalo de confianza para $\rho_{12|q_1, \dots, 1, p}$. El coeficiente de correlación parcial muestral es $r_{12|q_1, \dots, 1, p}$. El procedimiento será utilizar las tablas de David para $N-(p-q)$. Por ejemplo para la ilustración de la cosecha de heno antes dada, si queremos construir un intervalo para $\rho_{12|3}$ con coeficiente de confianza 0.95, como $r_{12|3} = 0.79$, utilizando la tabla $N-(p-q) = 20 - (2-1) = 19$, tenemos $0.52 < r_{12|3} < 0.92$.

Ejemplo 2. Analógicamente, si quisieramos utilizar la Z de Fisher para construir un intervalo de hipótesis para $\rho_{12|q_1, \dots, 1, p} = \rho_0$, frente a una alternativa bilateral, tenemos

$$Z = \frac{1}{2} \log \frac{1 + r_{12|q_1, \dots, 1, p}}{1 - r_{12|q_1, \dots, 1, p}}$$

$$\xi_0 = \frac{1}{2} \log \frac{1 + \rho_0}{1 - \rho_0}$$

Entonces $\sqrt{N-(p-q)-3} (Z - \xi_0)$ se comparan con los puntos de significación de una normal standarizada.

En el ejemplo de la cosecha de heno, si quisieramos contestar la hipótesis $\rho_{12|2} = 0$, al nivel $\alpha = 0.05$, tenemos $\xi_0 = 0$ y $\sqrt{20-1-3} (0.0973) = 0.3892$, y como $|0.3892| < 1.96$ aceptaremos la hipótesis.

4. EL COEFICIENTE DE CORRELACIÓN MULTIPLE

Estimación de la correlación multiple

El coeficiente de correlación multiple polacial lo estuvimos en capítulos anteriores. En aras de conveniencia (standarizaremos) la estimación para el caso Σ_1 por un lado y $\Sigma_2, \dots, \Sigma_p$ por otro, no pondremos indice alguno a R . Esta actuación no impone perdida de generalidad por cuanto las variables pueden transformarse para hacer válido lo anterior para cualquier otra actuación. Recordemos que la expresión para el coeficiente de correlación multiple polacial se ha dado por

$$R = \frac{\beta \Sigma_{22} \beta^T}{\sqrt{\sigma_{11} \beta \Sigma_{22} \beta^T}} = \sqrt{\frac{\beta \Sigma_{22} \beta^T}{\sigma_{11}}} = \sqrt{\frac{\sigma_{11} \Sigma_{22}^{-1} \sigma_{11}^T}{\sigma_{11}}}$$

donde β, σ_{11} y Σ_{22} son

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{pmatrix} \quad \beta = \sigma_{11}^{-1} \Sigma_{22}^{-1}$$

Dada una muestra x_1, \dots, x_N ($N > p$) estimamos Σ mediante $S = (N/(N-1)) \hat{\Sigma}_0$

$$\hat{\Sigma} = \frac{1}{N} A = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})(x_n - \bar{x})^T = \begin{pmatrix} \hat{\sigma}_{11} & \hat{\sigma}_{12} \\ \hat{\sigma}_{21} & \hat{\Sigma}_{22} \end{pmatrix}$$

y estimamos β mediante $\hat{\beta} = \hat{\sigma}_{11}^{-1} \hat{\Sigma}_{22}^{-1} = \sigma_{11}^{-1} A_{22}^{-1}$. Definiremos entonces el coeficiente de correlación multiple muestral como

$$R = \sqrt{\frac{\hat{\beta}^2 \hat{a}_{11}}{\hat{a}_{11}}} = \sqrt{\frac{\hat{\beta}^2 \hat{\Sigma}_{22}^{-1} \hat{\beta}^T}{\hat{a}_{11}}} = \sqrt{\frac{a_{11} A_{22}^{-1} \hat{\beta}^T}{a_{11}}}$$

Queremos de la estimación máxima-likelihood de $\hat{\beta}$ puede justificarse aplicando la teoría de inferencia presentada en capítulos anteriores referente a las estimaciones de funciones de los parámetros, teniendo en cuenta que $\hat{\beta}$, $\hat{\Sigma}_{22}$ pueden definirse mediante una transformación uno a uno de Σ . Otra expresión para R es

$$1 - R^2 = \frac{|\hat{\Sigma}|}{\hat{a}_{11} |\hat{\Sigma}_{22}|} = \frac{|A|}{a_{11} |A_{22}|}$$

R , $\hat{\beta}$ tienen la misma las mismas propiedades que \bar{R} , $\bar{\beta}$ poseen en la población. Por ejemplo, si todos los vectores de con (p_1) componentes que definen una combinación lineal $d x_{\alpha}^{(1)}$ de las componentes de $x_{\alpha}^{(1)}$, el vector $d = \hat{\beta}$ es el que minimiza $\sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - d(x_{\alpha}^{(1)} - \bar{x}^{(1)})]^2$. En efecto, en primer lugar observamos que

$$\sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - \beta(x_{\alpha}^{(1)} - \bar{x}^{(1)})] [x_{\alpha}^{(1)} - \bar{x}^{(1)}]^T = a_{11} - \hat{\beta} A_{22} = 0$$

por $\hat{\beta} = a_{11} A_{22}^{-1}$. Así

$$\sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - d(x_{\alpha}^{(1)} - \bar{x}^{(1)})]^2 = \sum_{\alpha=1}^N \{(x_{1\alpha} - \bar{x}_1) - \hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)}) + (\hat{\beta} - d)(x_{\alpha}^{(1)} - \bar{x}^{(1)})\}^2 =$$

$$= \sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - \hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})]^2 + (\hat{\beta} - d) A_{22} (\hat{\beta} - d)^T$$

y como A_{22} es definida positiva (excepto para muestras que caigan con probabilidad cero), el mínimo ocurrirá cuando $\hat{\beta} - d = 0$. Este mínimo es

$$\begin{aligned} \sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - \hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})]^2 &= a_{11} - 2 \hat{\beta} \sum_{\alpha=1}^N (x_{1\alpha} - \bar{x}_1) (x_{\alpha}^{(1)} - \bar{x}^{(1)})^T + \hat{\beta} A_{22} \hat{\beta}^T = \\ &= a_{11} - 2 \hat{\beta} a_{11}^T + a_{11} A_{22}^T A_{22} \hat{\beta}^T a_{11}^T = a_{11} - 2 a_{11} A_{22}^T a_{11}^T + a_{11} A_{22}^T a_{11}^T = \\ &= a_{11} - \hat{\beta} A_{22}^T \hat{\beta}^T = a_{11} - a_{11} A_{22}^T a_{11}^T = a_{11,2} \quad (\text{varianza condicionada para } \hat{\beta}). \end{aligned}$$

De este resultado puede darse una interesante interpretación geométrica. El vector de N componentes cuya α -ésima componente es $x_{1\alpha} - \bar{x}_1$ es, como en su momento vimos, la proyección del vector de las componentes cárnicas de la muestra sobre el plano ortogonal a la línea equiangular. Tenemos pues estos vectores $d(x_{\alpha}^{(1)} - \bar{x}^{(1)})$ a la α -ésima componente de un vector en el hiperplano determinado por los p_1 últimos vectores. Como $\sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - d(x_{\alpha}^{(1)} - \bar{x}^{(1)})]^2$ es la distancia entre el primer vector y la combinación lineal de los p_1 últimos vectores, $\hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})$ es una componente de un vector que minimiza esta distancia. La interpretación del hecho que $\sum_{\alpha=1}^N [(x_{1\alpha} - \bar{x}_1) - \hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})] [x_{\alpha}^{(1)} - \bar{x}^{(1)}]^T = 0$ es que el vector con componentes $(x_{1\alpha} - \bar{x}_1) - \hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})$ es perpendicular a cada uno de los p_1 últimos vectores. Así vemos que el vector $\{\hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})\}_{\alpha=1}^N$ es la proyección del primer vector sobre el hiperplano citado. El cuadrado de la longitud del vector proyección es

$$\sum_{\alpha=1}^N [\hat{\beta}(x_{\alpha}^{(1)} - \bar{x}^{(1)})]^2 = \hat{\beta} A_{22} \hat{\beta}^T = a_{11} A_{22}^T a_{11}^T$$

y la longitud del primer vector $\sum_{\alpha=1}^N (x_{1\alpha} - \bar{x}_1)^2 = a_{11}$. Así R es el seno del ángulo formado por el primer vector con su proyección.

Vimos anteriormente que el cosiente de medición ordinario es el coseno del ángulo formado por los vectores considerados en el plano ortogonal a la línea equiangular. Otra propiedad de R es que representa la medida media inclinación entre $x_{1\alpha}$ y la combinación lineal de las componentes de $x_{\alpha}^{(1)}$. Esto corresponde en la propiedad geométrica de que R es el seno del ángulo más pequeño entre el vector con componentes $(x_{1\alpha} - \bar{x}_1)$ y un vector en el hiperplano determinado por los otros p_1 vectores. Este resultado puede comprobarse desde cualquier punto de vista, el geométrico siendo el más fácil, apoyándose en el resultado precedente y de forma análoga a como lo hicimos con R .

Las interpretaciones geométricas vienen dadas todos ellos anteriormente de los vectores en el hipoplano $N-1$ dimensional ortogonal a la linea equiangular. Ya vimos anteriormente que el vector $(x_{11}-\bar{x}_1, \dots, x_{1N}-\bar{x}_1)$ en este hipoplano podia ser designado por (z_{11}, \dots, z_{1N}) donde las z_{ij} son las coordenadas referidas a un sistema de coordenadas $N-1$ dimensional en el hipoplano. Demostremos que las otras coordenadas se obtienen a partir de las antiguas mediante la transformación $x_{ij} = \sum_{k=1}^N z_{ik} b_{jk}$ donde B es una matriz ortogonal cuya ultima fila es $(1/\sqrt{p}, \dots, 1/\sqrt{p})$. Entonces

$$a_{ij} = \sum_{k=1}^N (x_{ik} - \bar{x}_i)(x_{jk} - \bar{x}_j) = \sum_{k=1}^{N-1} z_{ik} z_{jk}$$

En adelante cuando nos referimos a R definido anteriormente de z_{11} lo haremos como al "coeficiente de multicolinealidad simple sin restar las medias".

El cálculo de R impone la extracción de la raíz cuadrada del cociente de $a_{11} A_{22}^{-1} a_{11}'$ por a_{11} . Puesto que A no tiene directamente de las observaciones solo, probablemente, el íntero de $a_{11} A_{22}^{-1} a_{11}'$ implica alguna terminación especial.

Distribución del coeficiente de multicolinealidad simple cuando el promedio es cero.

Recordemos que

$$R^2 = \frac{a_{11} A_{22}^{-1} a_{11}'}{a_{11}}$$

entonces

$$1 - R^2 = 1 - \frac{a_{11} A_{22}^{-1} a_{11}'}{a_{11}} = \frac{a_{11} - a_{11} A_{22}^{-1} a_{11}'}{a_{11}} = \frac{a_{11,2}}{a_{11}}$$

$$\frac{R^2}{1 - R^2} = \frac{a_{11} A_{22}^{-1} a_{11}'}{a_{11,2}}$$

Para $q=1$ reescrivimos de la ecuación anterior (la referente al coeficiente de multicolinealidad parcial) establece que cuando $\beta=0$, es decir, cuando $\bar{R}=0$, $a_{11,2}$ se distribuye como $\sum_{\alpha=1}^{N-p} V_\alpha^2$ y $a_{11} A_{22}^{-1} a_{11}'$ se distribuye como $\sum_{\alpha=N-p+1}^{N-1} V_\alpha^2$, donde las V_α son independientes y cada una con distribución $N(0, \sigma_{11,2}^2)$. Entonces $a_{11,2}/\sigma_{11,2}$ y $a_{11} A_{22}^{-1} a_{11}' / \sigma_{11,2}$ se distribuyen independientemente como variables χ^2 con $N-p$ y $p-1$ grados de libertad respectivamente. Entonces

$$\frac{R^2}{1 - R^2} \cdot \frac{N-p}{p-1} = \frac{a_{11} A_{22}^{-1} a_{11}'}{\sigma_{11,2}^2} \cdot \frac{N-p}{p-1} = \frac{\chi_{p-1}^2}{\chi_{N-p}^2} \cdot \frac{N-p}{p-1} = F_{p-1, N-p}$$

Así, es decir, una F de Snedecor con $p-1$, $N-p$ grados de libertad. La densidad de F viene dada por

$$\frac{\Gamma(\frac{1}{2}(N-p))}{\Gamma(\frac{1}{2}(p-1)) \Gamma(\frac{1}{2}(N-p))} \left(\frac{p-1}{N-p} \right)^{\frac{1}{2}(p-1)} \cdot \left(1 + \frac{p-1}{N-p} x \right)^{-\frac{1}{2}(N-p)}$$

La densidad de R , definido como

$$R = \sqrt{\frac{\frac{p-1}{N-p} x}{1 + \frac{p-1}{N-p} x}} \quad \text{con } x \sim F_{p-1, N-p}$$

$$2 \frac{\Gamma(\frac{1}{2}(N-p))}{\Gamma(\frac{1}{2}(p-1)) \Gamma(\frac{1}{2}(N-p))} R^{p-2} (1 - R^2)^{\frac{1}{2}(N-p)-1}$$

Podemos unir todos estos resultados en el siguiente teorema.

TEOREMA - Sea R el coeficiente de correlación múltiple muestral entre $\mathbf{X}_1 \sim \mathbf{X}_p$ basado en una muestra de tamaño N tomada de una $N(\mu, \Sigma)$. Si $\bar{R}=0$ (es decir, si $(\sigma_{12}, \dots, \sigma_{1p}) = (\sigma_{ij}) = 0 = \beta$), entonces $[R^2/(1-R^2)] \cdot [(N-p)/(p-1)]$ se distribuye como una F de Snedecor con $p-1$ y $N-p$ grados de libertad.

Hay que señalar que $p-1$ es el número de componentes de $\mathbf{X}^{(1)}$ y $N-p = N-(p-1)-1$. Si el número de componentes de $\mathbf{X}^{(1)}$ fuera q , las cantidades serían $q-1$ y $N-q$ respectivamente.

Por otra parte la cantidad $R^2/(1-R^2)$ es la que se obtiene en teoría de la regresión para contrastar hipótesis acerca de los coeficientes de regresión, más precisamente, si la regresión de \mathbf{X}_1 sobre $\mathbf{X}_{2:p}$ es nula.

Si $\bar{R} \neq 0$ la distribución de R es mucho más difícil de obtener. Los comentarios de esta más tarde.

Contestos de hipótesis acerca de \bar{R} . ($H_0: \bar{R} \approx 0$)

vamos ahora a considerar el problema estadístico de contrastar la hipótesis $\bar{R}=0$ sobre la base de una muestra de tamaño N extraída de una población $N(\mu, \Sigma)$. Puesto que $\bar{R} \geq 0$ las alternativas consideradas son $\bar{R} > 0$.

Ostengamos en primer lugar el tet de la razón de verosimilitud de esta hipótesis. La función de verosimilitud es

$$L(\mu^*, \Sigma^*) = \frac{1}{(2\pi)^{\frac{1}{2}Np} |\Sigma^*|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} \sum_{\alpha} (x_{\alpha} - \mu^*)^T \Sigma^{*-1} (x_{\alpha} - \mu^*) \right].$$

Sea w la región del espacio paramétrico especificado por la hipótesis nula. El criterio de la razón de verosimilitud se basa en

$$\lambda = \frac{\max_{\mu^*, \Sigma^* \in w} L(\mu^*, \Sigma^*)}{\max_{\mu^*, \Sigma^* \in \Omega} L(\mu^*, \Sigma^*)}.$$

Aquí Ω es el espacio de μ^*, Σ^* definida positiva y w la región de este espacio donde $\bar{R} = \sqrt{\sigma_{11} \Sigma_{22} \sigma_{11}} / \sqrt{\sigma_{11}} = 0$, es decir donde $\sigma_{11} \Sigma_{22} \sigma_{11} = 0$. Como Σ_{22} es definida positiva esta condición equivale a $\sigma_{12} = 0$. El máximo de $L(\mu^*, \Sigma^*)$ sobre Ω se alcanza para $\mu^* = \hat{\mu} = \bar{x}$ y $\Sigma^* = \hat{\Sigma} = (1/N) A$ y viene dado por

$$\max_{\mu^*, \Sigma^* \in \Omega} L(\mu^*, \Sigma^*) = \frac{N^{\frac{1}{2}PN} e^{-\frac{1}{2}PN}}{(2\pi)^{\frac{1}{2}PN} |A|^{1/2}}.$$

En w , la función de verosimilitud es

$$L(\mu^*, \Sigma^* | \sigma_{11}^* = 0) = \frac{1}{(2\pi)^{\frac{1}{2}N} \sigma_{11}^{1/2}} \exp \left[-\frac{1}{2} \sum_{\alpha} (x_{\alpha} - \mu^*)^T \sigma_{11}^{-1} (x_{\alpha} - \mu^*) \right] \cdot \frac{1}{(2\pi)^{\frac{1}{2}(p-1)N} |\Sigma_{22}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} \sum_{\alpha} (x_{\alpha}^{(2)} - \mu^{(2)*})^T \Sigma_{22}^{-1} (x_{\alpha}^{(2)} - \mu^{(2)*}) \right]$$

~~.....~~

El primer factor se maximiza para $\mu^* = \hat{\mu}_1 = \bar{x}_1$ y $\sigma_{11}^* = \hat{\sigma}_{11} = (1/N) a_{11}$, y el segundo factor se maximiza para $\mu^{(2)*} = \hat{\mu}^{(2)} = \bar{x}^{(2)}$ y $\Sigma_{22}^* = \hat{\Sigma}_{22} = (1/N) A_{22}$. El valor máximo de la función es

$$\max_{\mu^*, \Sigma^* \in w} L(\mu^*, \Sigma^*) = \frac{N^{\frac{1}{2}N} \sigma_{11}^{-1/2}}{(2\pi)^{\frac{1}{2}N} a_{11}^{1/2}} \cdot \frac{N^{\frac{1}{2}(p-1)N} e^{-\frac{1}{2}(p-1)N}}{(2\pi)^{\frac{1}{2}(p-1)N} |A_{22}|^{1/2}}.$$

Así, el criterio de la razón de verosimilitud sería

$$\lambda = \frac{|A|^{1/2}}{a_{11}^{1/2} |A_{22}|^{1/2}} = (1 - R^2)^{\frac{1}{2}}$$

La región critica del tet vendrá dada por $\lambda < \lambda_0$, donde λ_0 se elige de manera que la probabilidad de la decisión, cuando $\bar{R}=0$, es precisamente α , nivel de significación elegido. Un tet equivalente sería

$$1 - \lambda^{2/N} = R^2 > 1 - \lambda_0^{2/N}.$$

Podemos construir un test a partir de $[R^2/(1-R^2)][(N-p)/(p-1)]$, que es una función monótona de R . 3 (11)

Para ello, teniendo en cuenta que si $\bar{R}=0$ el valorante anterior se distribuye como $F_{p-1, N-p}$, determinaremos la regla critica mediante la desigualdad

$$\frac{R^2}{1-R^2} \cdot \frac{N-p}{p-1} > F_{p-1, N-p}(\alpha)$$

donde $F_{p-1, N-p}(\alpha)$ es el punto de significación correspondiente a un nivel α . Este test es equivalente al obtenido mediante la razón de sensibilidad precisamente por ser una función monótona de R .

TEOREMA. - Dada una muestra x_1, \dots, x_n tomada de una $N(\mu, \Sigma)$, el test de la razón de sensibilidad a un nivel de significación α para la hipótesis $\bar{R}=0$, donde \bar{R} es el coeficiente de correlación múltiple entre \mathbf{x}_1 y $(\mathbf{x}_2, \dots, \mathbf{x}_p)$, viene dado por

$$\frac{R^2}{1-R^2} \cdot \frac{N-p}{p-1} > F_{p-1, N-p}(\alpha)$$

donde R es el coeficiente de correlación múltiple muestral definido como ante.

Del hecho de que la densidad de R es monótona creciente en \bar{R} , como venimos a intuirnos, podemos asegurar que el test definido en el teorema es uniformemente más potente para contradecir $\bar{R}=0$ en la clase de los test que dependen de R .

Como ademas R es invariante bajo transformaciones del tipo $x_{1x}^* = c x_{1x} + d$ y $x_{2x}^{(2)*} = c x_{2x}^{(2)} + d$ y es la única función del estadístico suficiente que es invariante, podemos concluir que el test es el test invariante uniformemente más potente.

Ejemplo. - Consideremos nuevamente el ejemplo de la cocción de huevo. El coeficiente de correlación múltiple muestral será, para

los datos

$$1 - R^2 = \frac{\begin{vmatrix} 1 & r_{12} & r_{13} \\ r_{12} & 1 & r_{23} \\ r_{13} & r_{23} & 1 \end{vmatrix}}{\begin{vmatrix} 1 & r_{23} \\ r_{23} & 1 \end{vmatrix}} = 0.357$$

y de aquí $R = 0.802$. Para contradecir la hipótesis a un nivel $\alpha=0.01$ de que la cocción de huevo es independiente de la cantidad de leche y de la temperatura, compararemos $[R^2/(1-R^2)][(20-3)/(3-1)] = 15.3$ con $F_{2,17}(0.01) = 6.11$ y concluirímos que no hay dependencia, pues rechazaremos la hipótesis nula $H_0: \bar{R}=0$.

Demostremos nuevamente que el test de independencia entre \mathbf{x}_1 y $(\mathbf{x}_2, \dots, \mathbf{x}_p) = \mathbf{x}_{(2)}$ es equivalente al test de la regresión de \mathbf{x}_1 sobre $\mathbf{x}_{(2)}$ (es decir, el valor condicional esperado de \mathbf{x}_1 dado $\mathbf{x}_{(2)} = \mathbf{x}_{(2)}$), que es $\mu_1 + \beta(x_{(2)} - \mu_{(2)})$, a una en el sentido de que el vector de regresión $\beta = 0$. $\hat{\beta} = a_{12} A_{22}^{-1}$ es la estimación usual mínima cuadrática de β , cuyo valor esperado es β y matriz de covarianzas $\hat{\sigma}_{12} A_{22}^{-1}$ (cuando las $\mathbf{x}_k^{(2)}$ son fijas) y $a_{11,2}/(N-p)$ es la estimación usual de σ_{12} . Entonces

$$\frac{R^2}{1-R^2} \cdot \frac{N-p}{p-1} = \frac{\hat{\beta} A_{22} \hat{\beta}'}{a_{11,2}} \cdot \frac{N-p}{p-1}$$

es el estadístico F usual para contradecir la hipótesis de nulidad para el vector de coeficientes de regresión de \mathbf{x}_1 sobre $\mathbf{x}_2 - \mathbf{x}_p$.

Es interesante resaltar, por último, que \bar{R} es la única función de μ y Σ que es invariante bajo cambios de escala y rotación de las variables y bajo cambios que impongan transformaciones lineales no singulares de $\mathbf{x}_{(2)}$. Analógicamente R es la única función de \bar{x} , $\bar{\Sigma}$, estadística suficiente para μ y Σ , que es invariante bajo transformaciones similares.

Distribución del coeficiente de correlación múltiple muestral cuando el postulativo es diferente de 0.

Quisiéramos de encontrar la distribución de R cuando la hipótesis nula no es cierta. Demostremos que esta distribución depende sólo del coeficiente de correlación múltiple poblacional, \bar{R} .

Consideremos en primer lugar la distribución marginal de $R^2/(1-R^2) = a_{11} A_{22}^{-1} a_{11}' / a_{11,2}$ dado $Z_{12}^{(2)} = Z_{22}^{(2)}$, $\alpha = 1, 2, \dots, n$. Bajo estas condiciones las Z_{12} se distribuyen independientemente como $N(\beta Z_{12}^{(2)}, \sigma_{11,2})$, donde $\beta = a_{11} A_{22}^{-1} a_{11}'$ y $\sigma_{11,2} = \sigma_{11} - \sigma_{12} Z_{22}^{(2)} \sigma_{22}^{(2)}$. Las condiciones son las de un teorema conocido cuando studiamos las correlaciones parciales (verse párrafo 3 de este mismo capítulo), con $Y_{12} = Z_{12} / \sqrt{1-R^2}$, $\Gamma = \beta$, $W_{12} = Z_{12}^{(2)} / (r-p-1)$, $\phi = \sigma_{11,2}$, $m=n$.

Dado que $A_{11} \cdot A_{11}^T = A_{11} - A_{11} A_{22}^{-1} A_{11}^T$ se corresponde con $\sum_{i=1}^m Y_i Y_i^T - G H G^T$, en consecuencia $A_{11} \cdot A_{11}^T / \sigma_{11,2}$ tiene una distribución χ^2 con $n-(p-1)$ grados de libertad. Por otra parte $A_{11} A_{22}^{-1} A_{11}^T = (A_{11} A_{22}^{-1}) A_{22} (A_{22}^{-1} A_{11}^T)$ se corresponde con $G H G^T$ y su distribución es como $\sum_{\alpha=0}^{\infty} U_{\alpha}^2$ ($\alpha = n-(p-1)+1, \dots, n$) donde $\text{Var}(U_{\alpha}) = \sigma_{11,2}$.

$$E(U_{n-p+2}, \dots, U_n) = P F^{-1},$$

donde, asumido, $F F^T = I (H = F^{-1}(F^T)^{-1})$. Dado que $A_{11} A_{22}^{-1} A_{11}^T / \sigma_{11,2}$ se distribuye como $\sum_{\alpha=0}^{\infty} U_{\alpha}^2 / \sqrt{\sigma_{11,2}}$, donde $\text{Var}(U_{\alpha} / \sqrt{\sigma_{11,2}}) = 1$

y

$$\sum_{\alpha=0}^{\infty} \left(\frac{E(U_{\alpha})}{\sqrt{\sigma_{11,2}}} \right)^2 = \frac{1}{\sigma_{11,2}} P F^{-1} (P F^{-1})^T = \frac{P H P^T}{\sigma_{11,2}} = \frac{\beta A_{22} \beta^T}{\sigma_{11,2}}$$

Así pues (condicionalmente) $A_{11} A_{22}^{-1} A_{11}^T / \sigma_{11,2}$ tiene una distribución χ^2 no centrada con $p-1$ grados de libertad y parámetros de no centralización $\beta A_{22} \beta^T / \sigma_{11,2}$. Podemos recoger todos estos resultados en el siguiente teorema.

TEOREMA. - Sea R el coeficiente de correlación multiple marginal entre X_1, \dots, X_p basado en N observaciones $(X_1, X_1^{(1)}, \dots, X_N, X_N^{(1)})$. La distribución condicional de $[R^2 / (1-R^2)] [((N-p)/(p-1))]$ dado $X_N^{(1)}$ fijo & una F de Snedecor no centrada con $p-1$ y $N-p$ grados de libertad y parámetro de no centralización $(\beta A_{22} \beta^T / \sigma_{11,2})$.

La densidad condicional de $F = [R^2 / (1-R^2)] [((N-p)/(p-1))]$ es de la forma

$$\frac{(p-1)}{(N-p)} \frac{e^{-\frac{1}{2} \beta A_{22} \beta^T / \sigma_{11,2}}}{P\left(\frac{1}{2}(N-p)\right)} \sum_{\alpha=0}^{\infty} \frac{\left(\frac{\beta A_{22} \beta^T}{\sigma_{11,2}}\right)^{\alpha} \left[\frac{(p-1)x}{N-p}\right]^{\frac{1}{2}(p-1)+\alpha-1}}{\alpha! \Gamma\left(\frac{1}{2}(p-1)+\alpha\right)} \frac{P\left(\frac{1}{2}(N-1)+\alpha\right)}{\left[1 + \frac{(p-1)x}{N-p}\right]^{\frac{1}{2}(N-1)+\alpha}}$$

y la densidad condicional de $W = R^2$ es $(dx = [(N-p)/(p-1)] (1-w)^{-2} dw)$

$$\frac{e^{-\frac{1}{2} \beta A_{22} \beta^T / \sigma_{11,2}}}{P\left(\frac{1}{2}(N-p)\right)} (1-w)^{\frac{1}{2}(N-p)+1} \sum_{\alpha=0}^{\infty} \frac{\left(\frac{\beta A_{22} \beta^T}{\sigma_{11,2}}\right)^{\alpha} w^{\frac{1}{2}(p-1)+\alpha-1}}{\alpha! \Gamma\left(\frac{1}{2}(p+1)+\alpha\right)} P\left(\frac{1}{2}(N-1)+\alpha\right)$$

Para obtener la densidad unconditional necesitaremos multiplicar la expresión anterior por la marginal de $Z_{\alpha}^{(1)} - Z_n^{(1)}$

Atendiendo a la conjunta de $W, Z_{\alpha}^{(1)}, \dots, Z_n^{(1)}$, y luego integrar respecto del último conjunto de variables, lo que nos dará, finalmente, la marginal de W . Tenemos

$$\frac{\beta A_{22} \beta^T}{\sigma_{11,2}} = \frac{\beta \sum_{\alpha=1}^n Z_{\alpha}^{(1)} Z_{\alpha}^{(1)T} \beta^T}{\sigma_{11,2}} = \sum_{\alpha=1}^n \left(\frac{\beta Z_{\alpha}^{(1)}}{\sqrt{\sigma_{11,2}}} \right)^2.$$

Puesto que la distribución de $Z_{\alpha}^{(1)}$ es $N(0, \sigma_{22})$, la distribución de $(\beta Z_{\alpha}^{(1)}) / \sqrt{\sigma_{11,2}}$ es normal con media cero y varianza

$$E\left(\frac{\beta Z_{\alpha}^{(1)}}{\sqrt{\sigma_{11,2}}}\right)^2 = \frac{E(\beta Z_{\alpha}^{(1)} Z_{\alpha}^{(1)T} \beta^T)}{\sigma_{11,2}} = \frac{\beta \text{Cov}(\beta^T)}{\sigma_{11,2} - \beta \text{Cov}(\beta^T)} = \frac{\beta \text{Cov}(\beta^T)}{1 - \beta \text{Cov}(\beta^T) / \sigma_{11,2}} = \frac{\bar{R}^2}{1 - \bar{R}^2}.$$

Así pues $(\beta A_{22} \beta^T / \sigma_{11,2}) / [\bar{R}^2 / (1-\bar{R}^2)]$ es una χ^2 con n grados de libertad. Ponemos $\bar{R}^2 / (1-\bar{R}^2) = \phi$. Dado que $\beta A_{22} \beta^T / \sigma_{11,2} = \phi X_n^2$. Calcularemos

$$\begin{aligned} E\left(e^{-\frac{1}{2}\phi X_n^2} \cdot \left(\frac{\phi X_n^2}{2}\right)^{\alpha}\right) &= \frac{\phi^{\alpha}}{2^{\alpha}} \int_0^{\infty} u^{\alpha} e^{-\frac{1}{2}\phi u} \frac{1}{2^{\frac{1}{2}n} \Gamma\left(\frac{1}{2}n\right)} u^{\frac{1}{2}n+\alpha} e^{-\frac{1}{2}u} du = \frac{\phi^{\alpha}}{2^{\alpha}} \int_0^{\infty} \frac{1}{2^{\frac{1}{2}n} \Gamma\left(\frac{1}{2}n\right)} u^{\frac{1}{2}n+\alpha-1} e^{-\frac{1}{2}(u+\phi)} du = \\ &= \frac{\phi^{\alpha}}{(1+\phi)^{\frac{1}{2}n+\alpha}} \frac{\Gamma\left(\frac{1}{2}n+\alpha\right)}{\Gamma\left(\frac{1}{2}n\right)} \int_0^{\infty} \frac{1}{2^{\frac{1}{2}n+\alpha} \Gamma\left(\frac{1}{2}n+\alpha\right)} \sqrt{\frac{1}{2}u+\frac{1}{2}\phi} \cdot e^{-\frac{1}{2}u} du = \frac{\phi^{\alpha}}{(1+\phi)^{\frac{1}{2}n+\alpha}} \cdot \frac{\Gamma\left(\frac{1}{2}n+\alpha\right)}{\Gamma\left(\frac{1}{2}n\right)}. \end{aligned}$$

Aplicando este resultado para matriz diagonal obtendremos una densidad para R^2 (Fisher 1928)

$$\frac{(1-R^2)^{\frac{1}{2}(n-p+1)} (1-\bar{R}^2)^{\frac{1}{2}n}}{\prod_{\mu=0}^{\infty} \left(\frac{1}{2}(n-p+\mu)\right) \Gamma\left(\frac{1}{2}n\right)} \sum_{\mu=0}^{\infty} \frac{(\bar{R}^2)^{\mu} (\bar{R}^2)^{\frac{1}{2}(p-1)+\mu-1} \Gamma^2\left(\frac{1}{2}n+\mu\right)}{\mu! \Gamma\left(\frac{1}{2}(p-1)+\mu\right)}.$$

EJEMPLOS

- ① Se impide que los niveles de reacción de dos compuestos biogénicos durante una situación de stress estén correlacionados. Los procesos biológicos que están implicados en este tipo de situaciones sugieren que la correlación, si existe, debe ser positiva. Para contrastar la hipótesis nula $H_0: \rho = 0$ a un nivel $\alpha = 0.01$ frente a la alterativa $H_1: \rho > 0$ debemos diseñar un experimento basado en un número suficiente, N , de ensayos independientes de manera que una correlación poblacional tan pequeña como $\rho = 0.20$ pueda ser detectada con una potencia 0.95. Los valores asimétricos de las probabilidades α y β reflejan las consecuencias relativas de cometer en cuenta una correlación falsa o pasar por alto una correlación real, aunque pequeña.

Utilizaremos como estadístico la Z de Fisher. En estas condiciones la regla crítica para la hipótesis nula viene dada por aquellos valores de Z tales que

$$(Z - Z_0) \sqrt{N-3} \geq Z_\alpha \rightarrow Z \geq Z_\alpha / \sqrt{N-3} + Z_0$$

donde

$$Z = \frac{1}{2} \log \frac{1+r}{1-r} \quad ; \quad Z_0 = \frac{1}{2} \log \frac{1+\rho_0}{1-\rho_0} \quad ; \quad Z_\alpha / P(Z \geq Z_\alpha) = \alpha.$$

en nuestro caso $\rho_0 = 0$ y además podemos llevar a cabo una aproximación mediante la normal, visto que Z_α se calcula a partir de las tablas de la normal tipificada.

La potencia del test es la probabilidad de ~~rechazar~~ rechazar la hipótesis nula cuando es falsa, por lo tanto, en nuestro caso y teniendo nuevamente en cuenta la aproximación mediante la normal, dicha potencia viene dada por

$$1 - \beta(\rho) = 1 - \phi \left[Z_\alpha + (Z_0 - \xi) \sqrt{N-3} \right] \rightarrow \phi \left(\frac{Z_\alpha / \sqrt{N-3} + Z_0 - \xi}{\sqrt{N-3}} \right) = \phi \left(Z_\alpha + (Z_0 - \xi) \sqrt{N-3} \right)$$

donde $\beta(\rho)$ es la probabilidad del error de tipo II, es decir, aceptar H_0 cuando es falsa y el verdadero valor es ρ .

Así las cosas, $Z_{0.01} = 2.33$ (obtenido de las tablas de la $N(0,1)$), $Z_0 = 0$, $\xi = \frac{1}{2} \log \frac{1+\rho}{1-\rho}$ que para $\rho = 0.20$, valor a partir del cual queremos detectar correlaciones con dicha potencia (0.95), vale $\xi = 0.2027$. Así pues la potencia del test debe de satisfacer la condición

$$0.95 = 1 - \phi(2.33 - 0.2027 \sqrt{N-3})$$

es decir,

$$\phi(2.33 - 0.2027 \sqrt{N-3}) = 0.05$$

como ϕ es la función de distribución de una $N(0,1)$, entonces

$$2.33 - 0.2027 \sqrt{N-3} = -1.645$$

y de aquí $N = 389$. Es decir, al menos 389 pares de observaciones deben registrarse en el estudio para que se verifiquen las condiciones exigidas. El número es válido, pero es el precio que debemos pagar para alcanzar los niveles α y β de probabilidad, bien rigurosos, deseados.

- ② Se ha aplicado determinado test de inteligencia a 933 individuos. Dicho test admite cuatro tipos de respuestas que se miden mediante otras tantas variables a las que designaremos por C , comportamiento, V , comprensión verbal, A , edad y E , educación. Para estas cuatro variables se ha obtenido la siguiente matriz de correlaciones

	C	V	A	E	
C	1	0.72	-0.44	0.60	
V		1	-0.13	0.68	
A			1	-0.29	
E				1	

Matriz de correlaciones

126.07	116.44	-53.98	20.85
207.47	-20.46	30.31	
119.38	-9.80		
9.58			

Los desviaciones standard para cada uno de ellos fueron 11.228, 14.404, 10.926 y 3.098, respectivamente. Las correlaciones parciales cuando mantenemos constante la edad y la educación vienen dadas por las siguientes matrices:

Edad constante

$$\begin{matrix} G & \begin{bmatrix} 1 & 0.74 & 0.55 \\ & 1 & 0.68 \\ & & 1 \end{bmatrix} \\ V & \\ E & \end{matrix}$$

Educación constante

$$\begin{matrix} G & \begin{bmatrix} 1 & 0.53 & -0.33 \\ & 1 & 0.10 \\ & & 1 \end{bmatrix} \\ V & \\ E & \end{matrix}$$

Análogamente, la correlación parcial $r_{12.34}$ entre G y V cuando ambas, A y E permanecen constantes vale

$$r_{12.34} = 0.62.$$

Si queremos llevar a cabo el contraste de hipótesis del tipo $H_0: \rho=0$ frente a $H_1: \rho \neq 0$, para $\alpha=0.05$, podemos utilizar la t de Student (ya sabemos que $\sqrt{N-2} r / \sqrt{1-r^2}$ es una t de Student con $N-2$ grados de libertad). Ahora bien, como $N=933$ supone una muestra de apantamiento, podemos aproximar muy bien la t mediante la normal, haciendo caso omiso de la pérdida de grados de libertad ($1+2$ según los censos) varianzada cuando mantenemos constantes 1 o 2 variables en el cálculo de las correlaciones parciales. En estos condicione los valores críticos para r tienen dadas por $r = \pm 0.064$, lo que significa que la hipótesis $H_0: \rho=0$ no rechazada cuando la aplicamos a cada uno de los coeficientes de correlación parcial obtenidos.

Calcularemos ahora el coeficiente de correlación múltiple del comportamiento frente las otras tres variables y los coeficientes de regresión correspondientes. Tenemos

$$\bar{R}^2 = 0.644 \quad \hat{\beta}' = [0.485, -0.346, 0.289]$$

Los coeficientes de regresión tienen dadas en las unidades de las variables originales.

Si queremos contrastar la hipótesis $H_0: \bar{R}=0$ podemos hacer uso del hecho de que $(\bar{R}^2 / 1 - \bar{R}^2) \cdot (N - p) / (p - 1)$, bajo la hipótesis nula se distribuye como una F con $p-1$ y $N-p$ grados de libertad. Tablas para $\alpha=0.05$, tenemos

$$F_{3,929}(0.05) \approx 2.60$$

Como

$$\frac{\bar{R}^2}{1 - \bar{R}^2} \cdot \frac{N - p}{p - 1} = \frac{0.644}{0.356} \cdot \frac{929}{3} = 560.18 > 2.60$$

rechazamos la hipótesis H_0 . Recordemos que este test es equivalente al efectuado para contrastar la hipótesis $\beta=0$, adoptar que $\bar{R} \neq 0$ impone aceptar que $\beta \neq 0$, o lo que es lo mismo, admitir una dependencia de tipo lineal entre G y las otras variables, ~~que~~ siendo $\hat{\beta}'$ una estimación de los correspondientes coeficientes.

Capítulo 4

El estadístico T^2 generalizado

1. INTRODUCCIÓN

Uno de los grupos de problemas, en estadística univariante, más importante es aquel que se ocupa de las cuestiones concernientes a la media de una distribución dada cuando la variancia de la distribución es desconocida. Sobre la base de una muestra se puede descartar el valor nula de la media o igual a un número determinado de anteriores, o bien dar un intervalo que contenga dicha media. El estadístico utilizado usualmente en estadística univariante es la diferencia entre la media muestral, \bar{x} , y la media hipotética poblacional dividida por la desviación típica muestral, s . Si la distribución muestral es $N(\mu, \sigma^2)$, entonces

$$t = \sqrt{N} \frac{\bar{x} - \mu}{s}$$

tiene una distribución t de Student con $N-1$ g.l., donde N es el número de observaciones en la muestra. Sobre la base de este hecho podemos llevar a cabo test de hipótesis $\mu = \mu_0$, donde μ_0 viene especificado, o bien podemos construir un intervalo de confianza para el parámetro desconocido μ .

El estadístico multivariante equivalente al mencionado del t viene dado por

$$T^2 = N(\bar{x} - \mu)' S^{-1} (\bar{x} - \mu),$$

donde \bar{x} es el vector media muestral y S es la matriz de covariancia muestral. Los impares de este estadístico y ~~cosas~~ de su utilización para resolver los problemas equivalentes en estadística multivariante, así como de otras utilizaciones del mismo. El primero en introducir el estadístico T^2 fue Hotelling en 1931 quien además estudió su distribución teórica bajo la hipótesis nula que se había planteado.

2. OBTENCIÓN Y DISTRIBUCIÓN DEL ESTADÍSTICO T^2 GENERALIZADO

Derivación del estadístico T^2 como una función del criterio de la varianza de verosimilitud

Como el estadístico T^2 tiene varios usos, comenzaremos demostrando que el test de la varianza de verosimilitud de la hipótesis $\mu = \mu_0$ sobre la base de una muestra de una población $N(\mu, \Sigma)$ se apoya plenamente en dicho estadístico T^2 . Supongamos que tenemos N observaciones x_1, \dots, x_N ($N > p$). La función de verosimilitud es

$$L(\mu, \Sigma) = \frac{1}{(2\pi)^{\frac{1}{2}pN}} \exp \left[-\frac{1}{2} \sum_{\alpha=1}^N (x_\alpha - \mu)' \Sigma^{-1} (x_\alpha - \mu) \right]$$

El criterio de la varianza de verosimilitud es

$$\lambda = \frac{\max_{\Sigma} L(\mu_0, \Sigma)}{\max_{\mu, \Sigma} L(\mu, \Sigma)}$$

Como ya sabemos, el máximo para el denominador se alcanza sustituyendo μ y Σ por sus correspondientes estimaciones máximas de verosimilitud

$$\hat{\mu}_\alpha = \bar{x}, \quad \hat{\Sigma}_\alpha = \frac{1}{N} \sum_{\alpha} (x_\alpha - \bar{x})' (x_\alpha - \bar{x})'$$

Cuando $\mu = \mu_0$, la función de verosimilitud se maximiza en

$$\hat{\Sigma}_w = \frac{1}{N} \sum_{\alpha} (x_\alpha - \mu_0)' (x_\alpha - \mu_0)$$

Como ya vimos en los momentos. Aplicando un lema utilizado en el capítulo 2 referente a la obtención del máximo de la función de verosimilitud podemos afirmar que

$$\max_{\Sigma, \mu} L(\mu, \Sigma) = \frac{1}{(2\pi)^{\frac{1}{2}pN} |\hat{\Sigma}_w|^{\frac{1}{2}N}} e^{-\frac{1}{2}pN} \quad \Rightarrow \quad \max_{\Sigma} L(\mu_0, \Sigma) = \frac{1}{(2\pi)^{\frac{1}{2}pN} |\hat{\Sigma}_w|^{\frac{1}{2}N}} e^{-\frac{1}{2}pN}$$

Aquí, el criterio de la tasa de verosimilitud 8

$$\lambda = \frac{|\hat{\Sigma}_n|^{\frac{1}{2N}}}{|\hat{\Sigma}_0|^{\frac{1}{2N}}} = \frac{\left| \sum (x_{\alpha} - \bar{x})(x_{\alpha} - \bar{x})' \right|^{\frac{1}{2N}}}{\left| \sum (x_{\alpha} - \mu_0)(x_{\alpha} - \mu_0)' \right|^{\frac{1}{2N}}} = \frac{|A|^{\frac{1}{2N}}}{|A + N(\bar{x} - \mu_0)(\bar{x} - \mu_0)'|^{\frac{1}{2N}}}$$

$$\text{con } A = \sum (x_{\alpha} - \bar{x})(x_{\alpha} - \bar{x})' = (N-1)S.$$

Para $|B| \neq 0$, utilizando una propiedad de las matrices, tenemos

$$\begin{vmatrix} B & C \\ D & E \end{vmatrix} = \begin{vmatrix} B & C \\ D & E \end{vmatrix} \cdot \begin{vmatrix} I & -B^{-1}C \\ 0 & I \end{vmatrix} = \begin{vmatrix} B & 0 \\ D & E - DB^{-1}C \end{vmatrix} = |B| \cdot |E - DB^{-1}C|$$

Aplicando dos veces esta identidad a $\lambda^{\frac{1}{2N}}$, tenemos

$$\lambda^{\frac{1}{2N}} = \frac{|A|}{|A + [N(\bar{x} - \mu_0)][N(\bar{x} - \mu_0)']|} = \frac{|A|}{\begin{vmatrix} 1 & N(\bar{x} - \mu_0)' \\ -N(\bar{x} - \mu_0) & A \end{vmatrix}} = \frac{|A|}{\begin{vmatrix} A & N(\bar{x} - \mu_0)' \\ -N(\bar{x} - \mu_0) & 1 \end{vmatrix}} =$$

$$= \frac{|A|}{|A| \cdot |1 + N(\bar{x} - \mu_0)' A^{-1}(\bar{x} - \mu_0)|} = \frac{1}{|1 + N(\bar{x} - \mu_0)' A^{-1}(\bar{x} - \mu_0)|} = \frac{1}{1 + T^2/(N-1)}$$

$$\text{donde } T^2 = N(\bar{x} - \mu_0)' S^{-1}(\bar{x} - \mu_0) = (N-1)N(\bar{x} - \mu_0)' A^{-1}(\bar{x} - \mu_0).$$

El test de la tasa de verosimilitud redefine mediante la región crítica (o región de rechazo)

$$\lambda \leq \lambda_0$$

donde λ_0 se elige de manera que la probabilidad de que $\lambda \leq \lambda_0$ cuando $\mu = \mu_0$ (la hipótesis nula cierta) es igual al nivel de significación. Si operamos adecuadamente la anterior expresión es equivalente a

$$T^2 \geq T_0^2,$$

$$\text{donde } T_0^2 = (N-1)(\chi_{\lambda_0}^{2/N} - 1).$$

Teorema. - El test de la tasa de verosimilitud de la hipótesis $\mu = \mu_0$ para la distribución $N(\mu, \Sigma)$ viene dado por $T^2 \geq T_0^2$, donde T^2 se define como anteriormente y T_0^2 se elige de manera que $\Pr(T^2 \geq T_0^2)$, bajo la hipótesis nula, sea igual al nivel de significación elegido.

El test basado en la t de Student, para el caso univariante, tiene la propiedad de que cuando se intenta la hipótesis $\mu = 0$ es invariante con respecto a transformaciones de escala. Si la variable aleatoria escalar X se distribuye como $N(\mu, \sigma^2)$ entonces $X^* = cX$ se distribuye $N(c\mu, c\sigma^2)$ que está en la misma clase que la hipótesis $E(X) = 0$ equivale a $E(X^*) = cE(X) = 0$. Si las observaciones x_{α} se transforman de la misma manera, $x_{\alpha}^* = cx_{\alpha}$, entonces, para $c > 0$, t^* calculada a partir de x_{α}^* es la misma que la t calculada a partir de las x_{α} . Así, cualquiera que sea la unidad de medida el estadístico resulta ser el mismo.

El test T^2 generalizado tiene la misma propiedad. Si el vector aleatorio \mathbf{X} se distribuye $N(\mu, \Sigma)$, entonces $\mathbf{X}^* = G\mathbf{X}$ (para $|G| \neq 0$) se distribuye $N(C\mu, C\Sigma C')$ que está en la misma clase. La hipótesis $E(\mathbf{X}) = 0$ equivale a $E(\mathbf{X}^*) = CE(\mathbf{X}) = 0$. Si las observaciones \mathbf{x}_{α} se transforman de la misma manera, $\mathbf{x}_{\alpha}^* = G\mathbf{x}_{\alpha}$, entonces T^2 y T^{*2} son iguales.

Esta consecuencia de que $\bar{x}^* = G\bar{x}$, $A^* = CAC'$ es del siguiente lema:

Lema. - Para cualquier matriz G , $p \times p$, no singular, H de igualdad características y K un vector cualquiera $K' H' K = (CK)' (CHC')^{-1} (CK)$.

Demonstración. - $(CK)' (CHC')^{-1} (CK) = K' C' (C^{-1} H^{-1} C^{-1} C K) = K' H' K$.

Demostremos más adelante que de todos los invariantes bajo estas transformaciones, este es uniformemente más potente. 4 (2)

Podemos dar ahora una interpretación geométrica de la raíz $\lambda^{1/N}$: suma del centro de la variancia y la similitud.

$$\lambda^{1/N} = \frac{|\sum (x_{\alpha} - \bar{x})(x_{\alpha} - \bar{x})|}{|\sum (x_{\alpha} - \mu_0)(x_{\alpha} - \mu_0)|}$$

en términos de paralelogramos. En una representación p-dimensional el numerador de $\lambda^{2/N}$ es la suma de los cuadrados de los volúmenes de todos los paralelogramos con ejes principales p vectores, cada uno con un extremo en el punto \bar{x} y el otro en x_{α} . El denominador es la suma de cuadrados de los volúmenes de los paralelogramos cuyos ejes principales tienen un extremo en μ_0 y el otro en x_{α} . Si la suma de los cuadrados de los volúmenes que involucran vectores que parten de \bar{x} , el centro de los x_{α} , es mucho menor que la de los volúmenes que involucran vectores que parten de μ_0 , entonces rechazaremos la hipótesis de que μ_0 es la media de la distribución.

Existe también una interpretación en el caso de una representación N-dimensional. Sea $y_i = (x_{i1}, \dots, x_{iN})$ el vector i-simo. Entonces

$$\sqrt{N} \bar{x}_i = \sum_{\alpha=1}^N \frac{1}{\sqrt{N}} x_{i\alpha}$$

y la distancia desde el origen de la proyección de y_i en la línea equiangular (los ejes directos $\langle \bar{x}_1, \bar{x}_2, \dots, \bar{x}_N \rangle$). las coordenadas de la proyección son $(\bar{x}_1, \dots, \bar{x}_i)$. Entonces $(x_{i1} - \bar{x}_1, \dots, x_{iN} - \bar{x}_i)$ es la proyección de y_i sobre el plano, aparte del origen, perpendicular a la línea equiangular. El numerador de $\lambda^{2/N}$ es el cuadrado del volumen p-dimensional del paralelogramo con ejes principales, los vectores $(x_{i1} - \bar{x}_1, \dots, x_{iN} - \bar{x}_i)$. Un punto $(x_{i1} - \mu_0, \dots, x_{iN} - \mu_0)$ resultaría a partir de y_i una traslación paralela a la línea equiangular (a una distancia $\sqrt{N}(\mu_0)$). El denominador es el cuadrado del volumen de los paralelogramos con ejes principales ambos vectores. Entonces $\lambda^{2/N}$ es la suma de los cuadrados de dichos volúmenes.

La distribución de T^2

Demostremos en esta sección la distribución de T^2 bajo condiciones generales, incluido el caso en que la hipótesis nula no es cierta. Sea $T^2 = Y^T S^{-1} Y$, donde Y se distribuye $N(\mu, \Sigma)$ y nS se distribuye independientemente como $\sum_{\alpha=1}^n Z_{\alpha} Z_{\alpha}'$ con Z_{α} independientes entre sí, cada una con una distribución $N(0, I)$. El T^2 aquí utilizado es un caso especial de esta definición con $Y = \sqrt{N}(\bar{x} - \mu_0)$ y $S = \sqrt{N}(\mu - \mu_0)$ y $n = N - 1$. Sea D una matriz no singular tal que $D\Sigma D' = I$, y definimos

$$Y^* = DY$$

$$\Sigma^* = DSD'$$

$$V^* = DV.$$

Entonces $T^2 = Y^* \Sigma^{*-1} Y^*$, de acuerdo con el lema anterior, donde Y^* se distribuye $N(V^*, I)$ y $n\Sigma^*$ se distribuye independientemente como $\sum_{\alpha=1}^n Z_{\alpha}^* Z_{\alpha}' = \sum_{\alpha=1}^n DZ_{\alpha}(DZ_{\alpha})'$ con $Z_{\alpha}^* = DZ_{\alpha}$ independientes entre sí, cada una con distribución $N(0, I)$. Observamos que $V^T \Sigma^* V = V^T (I)^{-1} V^* = V^* V^*$.

Sea la primera fila de una matriz ortogonal Q , de dimensión $p \times p$, definida mediante

$$q_{1i} = \frac{y_{i1}^*}{\sqrt{y_{11}^* y_{11}}} \quad i = 1, \dots, p$$

lo que es permisible por cuanto se ha de restringir $\sum q_{1i}^2 = 1$. Las otras $p-1$ filas pueden definirse de forma arbitraria de acuerdo con una propiedad de tales matrices. Como Q depende de las y^* se tratará de una matriz aleatoria. Sean ahora

$$U = QY^*$$

$$B = Qn\Sigma^* Q'$$

De la definición de Q se sigue:

$$u_1 = \sum q_{1i} y_{i1}^* = \sqrt{y_{11}^*} y_{11}^*$$

$$u_j = \sum q_{ji} y_{i1}^* = \sqrt{y_{11}^*} y_{11}^* \sum q_{ji} q_{1i} = 0, \quad j \neq 1.$$

Entonces

$$\frac{T^2}{n} = U' B^{-1} U = (U_1 \ 0 \dots 0) \begin{bmatrix} b^{11} & b^{12} & \cdots & b^{1P} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ b^{P1} & b^{P2} & \cdots & b^{PP} \end{bmatrix} \begin{pmatrix} U_1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} = U_1^2 \cdot b^{11}$$

donde $(b^{ij}) = B^{-1}$, haciendo uso de una propiedad de las matrices particionadas tenemos,

$$1/b^{11} = b_{11} - b_{(1)} \cdot B_{22}^{-1} b'_{(1)} = b_{11,2} - p$$

donde

$$B = \begin{pmatrix} b_{11} & b_{12} \\ b_{21} & B_{22} \end{pmatrix},$$

$\gamma T^2 = n U_1^2 / b_{11,2-p} = n Y^{**} Y^* / b_{11,2-p}$. La distribución condicional de B dado Q es la de $\sum_{\alpha=1}^n V_\alpha \sqrt{\lambda_\alpha}$, donde condicionalmente los $V_\alpha = Q Z_\alpha^*$ son independientes entre si, cada uno con una distribución $N(0, I)$.

Por otra parte, aplicando las propiedades obtenidas en el capítulo anterior para la distribución de las matrices AII.2, cuando consideramos el coeficiente de correlación parcial, sabemos que $b_{11.2-p}$ se distribuye condicionalmente como $\sum_{\alpha=1}^{n-(p-1)} W_\alpha^2$ donde condicionalmente los W_α son independientes entre sí, cada una $N(0,1)$; y derivando, $b_{11.2-p}$ se distribuye condicionalmente como una χ^2 con $n-(p-1)$ gr. de libertad. Puesto que la distribución condicional de $b_{11.2-p}$ no depende de Q , ello significa que se distribuye incondicionalmente como χ^2 . La cantidad y^*y^* tiene una distribución χ^2 no centrada con p grados de libertad y parámetros de nocentrabilidad $V^*V^* = V^T Z^{-1} V$. De definitiva T^*y^* se distribuye como la razón de una χ^2 no centrada y una χ^2 independiente.

TEOREMA. - Sea $T^2 = Y^T S^{-1} Y$, donde Y se distribuye $N(\mathbf{0}, \Sigma)$ y S es independientemente como $\sum_{i=1}^n Z_i Z_i^T$ con Z_i independiente entre sí, cada una $N(\mathbf{0}, \Sigma)$. Entonces $(T^2/n) [(n-p+1)/p]$ se distribuye como una F no centrada con p y $n-p+1$ grados de libertad ~~que es un cuadrado~~, y parámetro de no centralización $\mathbf{v}^T \Sigma^{-1} \mathbf{v}$. Si $\mathbf{v} = \mathbf{0}$ la distribución es una F centrada.

Entonces a esta distribución una distribución T^2 con n grados de libertad.

COROLARIO. - Sea x_1, \dots, x_N una muestra de una $N(\mu, \Sigma)$ y sea $T^2 = N(\bar{x} - \mu_0)' S^{-1} (\bar{x} - \mu_0)$. La distribución de $[T^2/(N-1)] [(N-p)/p]$ es una F no centrada con p y $N-p$ grados de libertad y parámetro de no centralización $N(\mu - \mu_0)' \Sigma^{-1} (\mu - \mu_0)$. Si $\mu = \mu_0$, entonces la distribución es una F centrada.

la densidad y tablas de la F no centrada se estudiarán en un párrafo posterior.

3. USOS DEL ESTADÍSTICO T^2

Ya hemos visto que el test de la varianza de verosimilitud de la hipótesis $\mu = \mu_0$ sobre la base de una muestra aleatoria N de una $N(\mu, \sigma^2)$ es equivalente a

$$T^2 \geq T_0^2$$

Si el nivel de significación es α , elegimos T_0 a partir de una tabla F centrada de manera que

$$T_0^2 = \frac{(N-1)p}{N-p} F_{p, N-p}(x),$$

siendo $F_{p,N-p}(x)$ el punto que dejara a su derecha una área α . La elección del nivel de significación depende o puede basarse en la potencia del test, de los más oportunos máximos.

El estadístico T^2 se calcula con facilidad a partir de la muestra. Un efecto

$$A^{-1}(\bar{x} - \mu_0) = b$$

S la solución de la ecuación

$$Ab = (\bar{x} - \mu_0)$$

entomol.

$$\frac{T^2}{N-1} = N(\bar{x} - \mu_0)' b$$

Observese que $T^2/(N-1)$ es la raíz no nula de

$$\left| N(\bar{x} - \mu_0)(\bar{x} - \mu_0)' - \lambda A \right| = 0.$$

LEMÁ .- Si v es un vector de p componentes y si B es una matriz no singular de orden p , entonces $v'B^{-1}v$ es la raíz no nula de

$$|vv' - \lambda B| = 0.$$

Demostración.- La raíz, λ_1 , no nula de la ecuación anterior está asociada con un vector característico β que satisface

$$v'B'\beta = \lambda_1 B\beta.$$

Como $\lambda_1 \neq 0$, $v'\beta \neq 0$. Multiplicando por la izquierda por $v'B^{-1}$, tenemos

$$(v'B^{-1}v)(v'\beta) = \lambda_1(v'\beta),$$

lo que demuestra el lema. En el caso anterior $v = \sqrt{N}(\bar{x} - \mu_0)$ y $B = A$.

Una región de confianza para el vector media

Si μ es la media de $N(\mu, \Sigma)$ tenemos que la probabilidad de extraer una muestra de tamaño N con media \bar{x} y matriz de covarianzas S , tal que

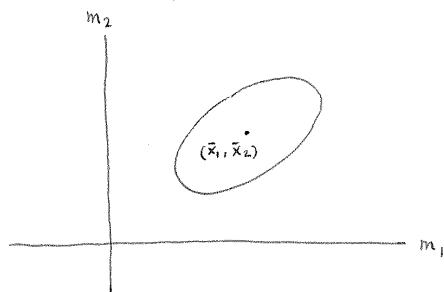
$$N(\bar{x} - \mu)' S^{-1} (\bar{x} - \mu) \leq T_\alpha^2(\alpha)$$

es precisamente $1-\alpha$.

Así pues, si calculamos la expresión anterior para una muestra particular, tenemos una confianza $1-\alpha$ de que la citada expresión sea cierta en lo que a μ se refiere. La desigualdad

$$N(\bar{x} - \mu)' S^{-1} (\bar{x} - \mu) \leq T_\alpha^2(\alpha)$$

es de interior y la frontera de un elipsoidal p-dimensional con centro en \bar{x} y cuyo tamaño y forma dependen de S^{-1} y α . (Véase la figura para el caso bidimensional). Afirmamos que μ está en el elipsoidal. Lógicamente el elipsoidal es aleatorio puesto que depende de muestras aleatorias.



Problema de dos muestras

Otra situación en la cual se utiliza el estadístico T^2 es aquella en la que se pretende contrastar la hipótesis de la igualdad de medias para dos poblaciones normales multivariantes cuyas matrices de covarianza se desconocen pero se suponen iguales. Supongamos $y_1^{(i)} - y_{N_i}^{(i)}$ una muestra de $N(\mu^{(i)}, \Sigma)$, $i=1,2$. Queremos contrastar la hipótesis $\mu^{(1)} = \mu^{(2)}$. $\bar{y}^{(i)}$ se distribuye $N(\mu^{(i)}, 1/N_i \Sigma)$. Consecuentemente $\sqrt{N_1 N_2 / (N_1 + N_2)} (\bar{y}^{(1)} - \bar{y}^{(2)})$ se distribuye como $N(\mu^{(1)} - \mu^{(2)}, \Sigma)$ y si la hipótesis nula $\mu^{(1)} = \mu^{(2)}$ es cierta esta distribución será $N(0, \Sigma)$. Si hacemos

$$S = \frac{1}{N_1 + N_2 - 2} \left\{ \sum_{x=1}^{N_1} (y_x^{(1)} - \bar{y}^{(1)}) (y_x^{(1)} - \bar{y}^{(1)})' + \sum_{x=1}^{N_2} (y_x^{(2)} - \bar{y}^{(2)}) (y_x^{(2)} - \bar{y}^{(2)})' \right\}$$

entonces $(N_1 + N_2 - 2) S$ se distribuye como $\sum_{x=1}^{N_1 + N_2 - 2} Z_x Z_x'$ con $Z_x \sim N(0, \Sigma)$. Así pues

$$T^2 = \frac{N_1 N_2}{N_1 + N_2} (\bar{y}^{(1)} - \bar{y}^{(2)})' S^{-1} (\bar{y}^{(1)} - \bar{y}^{(2)})$$

se distribuye como T^2 con $N_1 + N_2 - 2$ grados de libertad. La regla crítica viene dada por

$$T^2 \geq \frac{(N_1+N_2-2)p}{N_1+N_2-p-1} F_{p, N_1+N_2-p-1}(\alpha) \quad \text{con nivel de significación } \alpha.$$

Un ejemplo de aplicación de esta teoría lo encontramos en Fisher (1936). Sea x_1 = longitud del sépalo, x_2 = anchura del sépalo, x_3 = longitud del pétalo y x_4 = anchura del pétalo. Se toman 50 observaciones de la población Iris versicolor (1) y otras 50 de la población Iris setosa (2). Los datos resumidos, en centímetros, son los siguientes:

$$\bar{x}^{(1)} = \begin{pmatrix} 5.936 \\ 2.770 \\ 4.260 \\ 1.326 \end{pmatrix}, \quad \bar{x}^{(2)} = \begin{pmatrix} 5.006 \\ 3.428 \\ 1.462 \\ 0.246 \end{pmatrix}, \quad S = \begin{pmatrix} 19.1434 & 9.0356 & 4.7634 & 3.2394 \\ 9.0356 & 11.8658 & 4.6232 & 2.4746 \\ 4.7634 & 11.8658 & 12.2978 & 3.8744 \\ 3.2394 & 2.4746 & 3.8744 & 2.4604 \end{pmatrix}$$

El valor de $T^2/98 \approx 26.334$ y $T^2/98 \times 95/4 = 625.5$. Este valor es altamente significativo (comparado con el punto F para 4 y 95 grados de libertad), en consecuencia rechazaremos la hipótesis de igualdad de medias en ambas poblaciones.

Un problema de q-muestras

Después de considerar el anterior ejemplo, Fisher obtiene una tercera muestra de una población a la que supone con igual matriz de covarianzas. Tiene a cabo 50 medidas, las mismas, sobre individuos Iris longicauda. Existe una razón teórica para creer que la estructura genética de estas tres poblaciones es tal que sus vectores medias están relacionados como sigue:

$$3\mu^{(1)} = \mu^{(3)} + 2\mu^{(2)}$$

siendo $\mu^{(3)}$ el vector media de la tercera población.

Se trata de un caso particular del siguiente problema general. Sean $\{\bar{x}_\alpha^{(i)}\}_{\alpha=1, \dots, N_i, i=1, \dots, q}$ muestras extraídas de $N(\mu^{(i)}, \Sigma)$, $i=1, \dots, q$, respectivamente. Hagamos la siguiente hipótesis H:

$$\sum_{i=1}^q \beta_i \bar{x}_\alpha^{(i)} = \mu,$$

donde β_1, \dots, β_q son scalares dados y μ un vector dado. El criterio a aplicar en esta situación es

$$T^2 = c \left(\sum_{i=1}^q \beta_i \bar{x}_\alpha^{(i)} - \mu \right)' S^{-1} \left(\sum_{i=1}^q \beta_i \bar{x}_\alpha^{(i)} - \mu \right),$$

$$\text{donde } \bar{x}^{(i)} = \frac{1}{N_i} \sum_{\alpha=1}^{N_i} x_\alpha^{(i)}, \quad \left(\sum_{i=1}^q N_i - q \right) S = \sum_{i=1}^q \sum_{\alpha=1}^{N_i} (x_\alpha^{(i)} - \bar{x}^{(i)}) (x_\alpha^{(i)} - \bar{x}^{(i)})', \quad 1/c = \sum_{i=1}^q \frac{\beta_i^2}{N_i}.$$

Esta T^2 tiene una distribución T^2 de Hotelling con $\sum_{i=1}^q N_i - q$ grados de libertad. Fisher, en realidad, supuso que las matrices de covarianzas podían ser diferentes y solvió el problema aplicando una técnica de los cuadrados menores más grande.

Un problema de mínima

Consideremos el siguiente contraste de hipótesis H: $\mu_1 = \mu_2 = \dots = \mu_p$ donde la base de una muestra x_1, \dots, x_N extraída de una población $N(\mu, \Sigma)$ donde $\mu = (\mu_1, \dots, \mu_p)$. Sea C cualquier matriz $(p-1) \times p$ de rango $p-1$ tal que

$$CE = 0$$

donde $E = (1, \dots, 1)$. Entonces

$$y_\alpha = C x_\alpha, \quad \alpha = 1, \dots, N$$

tiene media Cμ y matriz de covarianzas $C\Sigma C'$. La hipótesis H impone ahora $C\mu = 0$, en efecto de $CE = 0$ obtenemos

$$\sum_{j=1}^p C_{ij} = 0, \quad i = 1, \dots, p-1$$

$$\text{pero } C\mu = \begin{bmatrix} \sum_{j=1}^p C_{1j} \mu_j \\ \vdots \\ \sum_{j=1}^p C_{pj} \mu_j \end{bmatrix} \quad \text{si } H \text{ es cierta} \quad \sum_{j=1}^p C_{ij} \mu_j = \mu \left(\sum_{j=1}^p C_{ij} \right) = 0, \quad \text{donde } \mu = \mu_1 = \mu_2 = \dots = \mu_p.$$

Utilizaremos entonces el estadístico

$$T^2 = N \bar{y}^T S^{-1} \bar{y}$$

$$\text{con } \bar{y} = \frac{1}{N} \sum_{\alpha=1}^N y_\alpha = G \bar{x}, \quad S = \frac{1}{N-1} \sum_{\alpha=1}^N (y_\alpha - \bar{y})(y_\alpha - \bar{y})^T = \frac{1}{N-1} G \left[\sum_{\alpha=1}^N (x_\alpha - \bar{x})(x_\alpha - \bar{x})^T \right] G^T$$

Este estadístico tiene una distribución T^2 con $N-1$ grados de libertad para una distribución $(p-1)$ -dimensional. Este estadístico T^2 es invariante bajo cualquier transformación lineal en las $p-1$ dimensiones que sea ortogonal a E . En consecuencia el estadístico es independiente de la elección que se haga para G .

Un ejemplo que ilustra este problema viene dado por Rao (1948). Sea N la cantidad de cuatros extraída de un arbol productor de cebolla, en la ~~zona~~ parte Norte del ~~misma~~ ^{número}, sean E, S, W definidas de forma similar para las ~~cuatras~~ ^{Oeste, Este, Sur, Norte} respectivamente. El conjunto de estas cuatro cantidades para un mismo arbol se considera una observación de una normal 4-variente. La hipótesis a dilucidar es si los arboles tienen la misma cantidad de cebolla en cada una de sus cuatras. Hacemos la siguiente transformación,

$$y_1 = N - E - W + S$$

$$y_2 = S - W$$

$$y_3 = N - S.$$

El número de observaciones es de 28.

El vector de medias es

$$\bar{y} = \begin{bmatrix} 8.86 \\ 4.50 \\ 0.86 \\ 6.33 \end{bmatrix}$$

La matriz de covarianzas para y es

$$S = \begin{bmatrix} 128.72 & 61.41 & -21.02 \\ 61.41 & 56.93 & -28.30 \\ -21.02 & -28.30 & 63.53 \end{bmatrix}$$

El valor de $T^2/(N-1) \approx 0.768$. El estadístico $0.768 \cdot \frac{25}{3} = 6.402$ es una F con 3, 25 grados de libertad. Para $\alpha = 0.05$ $F_{3,25} = 4.68$ y rechazariamos la hipótesis.

4. LA DISTRIBUCIÓN DE T^2 BAJO HIPÓTESIS ALTERNATIVAS: LA FUNCIÓN POTENCIA.

Hemos visto anteriormente que $(T^2/n)/(N-p)/p$ tiene una distribución F no centrada. Se trata ahora de estudiar las distribuciones χ^2 y F no centradas, la tabulación de esta última y su aplicación a procedimientos basados en T^2 .

La distribución χ^2 es la distribución de la suma de cuadrados de variables aleatorias (escalares) independientes normales con media 0 y varianza 1; la χ^2 no centrada es la generalización de la anterior cuando las medias pueden ser distintas de cero. Sea Y un vector de p componentes distribuido $N(\mu, I)$. Sea Q una matriz ortogonal cuya primera fila viene dada por

$$q_{1i} = \frac{\mu_i}{\sqrt{\mu_i^2}}$$

Entonces $Z = QY$ se distribuye $N(\lambda, I)$, donde $\lambda = [\lambda_1, \dots, \lambda_p]^T$ y $Z = \sqrt{\lambda^T \lambda}$, como vimos anteriormente (apartado 2 de este Capítulo). Sea $V = Y^T Y = Z^T Z = \sum_{i=1}^p Z_i^2$, entonces $W = \sum_{i=2}^p Z_i^2$ tiene una distribución χ^2 con $p-1$ grados de libertad y Z_1, W tienen una densidad conjunta

$$\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(Z_1 - \lambda_1)^2} \cdot \frac{1}{2^{\frac{1}{2}(p-1)} \Gamma(\frac{1}{2}(p-1))} W^{\frac{1}{2}(p-1)-1} e^{-\frac{1}{2}W} = C e^{-\frac{1}{2}(Z_1^2 + Z_2^2 + \dots + Z_p^2 + W)} W^{\frac{1}{2}(p-3)} e^{\frac{1}{2}Z_1^2} =$$

$$= C e^{-\frac{1}{2}(Z_1^2 + Z_2^2 + \dots + Z_p^2 + W)} W^{\frac{1}{2}(p-3)} \sum_{n=0}^{\infty} \frac{Z_1^{2n} Z_2^{2(p-3-n)}}{n! (p-3-n)!}$$

donde $C = 2^{\frac{1}{2}p} \sqrt{\pi} \prod_{i=1}^p \Gamma\left(\frac{1}{2}(p-i)\right)$. La densidad conjunta de $V = W + Z_1^2$ y Z_1 se obtiene sustituyendo $W = V - Z_1^2$ (el Jacobiano

de la transformación viendo la 1),

$$G e^{-\frac{1}{2}(z^2+v)} (v-z_1)^{\frac{1}{2}(p-3)} \sum_{\alpha=0}^{\infty} \frac{z_1^\alpha v^\alpha}{\alpha!}.$$

La densidad conjunta de V y $U = z_1/\sqrt{v}$ es ($dz_1 = \sqrt{v} du$)

$$G e^{-\frac{1}{2}(z^2+v)} v^{\frac{1}{2}(p-2)} (1-u^2)^{\frac{1}{2}(p-3)} \sum_{\alpha=0}^{\infty} \frac{z_1^\alpha u^\alpha v^{\frac{1}{2}\alpha}}{\alpha!}$$

Mediante el campo de variación de z_1 , dado $V, [-\sqrt{v}, \sqrt{v}]$ y el de $u, [-1, 1]$. Cuando integramos en esta última expresión respecto de u , términos a terminos, los términos para α impar dan una integral nula más para tales términos se trata de una función impar de u . En las otras integramos dividiendo el cuadrado $u = \sqrt{s}$ ($du = \frac{1}{2} ds/\sqrt{s}$), obtenemos

$$\int_{-1}^1 (1-u^2)^{\frac{1}{2}(p-3)} u^{2\beta} du = 2 \int_0^1 (1-u^2)^{\frac{1}{2}(p-3)} u^{2\beta} du = \int_0^1 (1-s)^{\frac{1}{2}(p-3)} s^{\beta-\frac{1}{2}} ds = B\left[\frac{1}{2}(p-1), \beta + \frac{1}{2}\right] =$$

$$= \frac{\Gamma\left[\frac{1}{2}(p-1)\right] \cdot \Gamma\left(\beta + \frac{1}{2}\right)}{\Gamma\left(\frac{1}{2}p + \beta\right)}$$

de acuerdo con la relación existente entre las funciones Beta y Gamma.

La densidad de V tiene más dada por:

$$\frac{1}{2^{\frac{1}{2}p} \sqrt{\pi}} e^{-\frac{1}{2}(z^2+v)} v^{\frac{1}{2}p-1} \sum_{\beta=0}^{\infty} \frac{(z^2)^\beta v^\beta}{(2\beta)!} \cdot \frac{\Gamma\left(\beta + \frac{1}{2}\right)}{\Gamma\left(\frac{1}{2}p + \beta\right)}.$$

Esta es la densidad de un χ^2 no centrada con p grados de libertad y parámetro de no centralización z^2 .

TEOREMA - Si el vector Y de p componentes se distribuye $N(U, I)$, entonces $V = Y'Y$ tiene una densidad χ^2 no centrada con p grados de libertad, siendo $z^2 = U'U$ el parámetro de no centralización.

Sea ahora V una χ^2 no centrada con p grados de libertad y parámetros de no centralización z^2 , sea W , independiente de la anterior, una χ^2 con m grados de libertad. Vamos a encontrar la densidad de $F = (V/p)/(W/m)$, que es una F no centrada con parámetro z^2 . La densidad conjunta de V y W es la densidad de V multiplicada por la de W , que es $2^{\frac{1}{2}m} \Gamma\left(\frac{1}{2}m\right) W^{\frac{1}{2}m-1} e^{-\frac{1}{2}w}$. La densidad conjunta de F , W ($dW = pw dw/dm$) es

$$\frac{z^{-\frac{1}{2}z^2}}{2^{\frac{1}{2}(p+m)} \sqrt{\pi} \Gamma\left(\frac{1}{2}m\right)} \cdot \frac{-\frac{1}{2}w(1+pf/m)}{\sum_{\beta=0}^{\infty} \frac{(z^2)^\beta \Gamma\left(\beta + \frac{1}{2}\right)}{(2\beta)! \Gamma\left(\frac{1}{2}p+\beta\right)} \left(\frac{pf}{m}\right)^{\frac{1}{2}p+\beta-1} w^{\frac{1}{2}(p+m)+\beta-1}}.$$

La densidad marginal se obtiene integrando para w entre 0 y ∞ ,

$$\frac{p z^{-\frac{1}{2}z^2}}{m \sqrt{\pi} \Gamma\left(\frac{1}{2}m\right)} \sum_{\beta=0}^{\infty} \frac{(2z^2)^\beta \Gamma\left(\beta + \frac{1}{2}\right)}{(2\beta)! \Gamma\left(\frac{1}{2}p+\beta\right)} \left(\frac{pf}{m}\right)^{\frac{1}{2}p+\beta-1} \frac{\Gamma\left(\frac{1}{2}(p+m)+\beta\right)}{(1+pf/m)^{\frac{1}{2}(p+m)+\beta}}.$$

Si utilizamos la fórmula de la duplicación de la función gamma

$$(2\beta)! = \Gamma(2\beta+1) = \Gamma\left(\beta + \frac{1}{2}\right) \Gamma\left(\beta + \frac{1}{2}\right) 2^{2\beta}/\sqrt{\pi}$$

La densidad queda finalmente

$$\frac{p z^{-\frac{1}{2}z^2}}{m \Gamma\left(\frac{1}{2}m\right)} \sum_{\beta=0}^{\infty} \frac{(z^2)^{\beta} (pf/m)^{\frac{1}{2}p+\beta-1} \Gamma\left(\frac{1}{2}(p+m)+\beta\right)}{\beta! \Gamma\left(\frac{1}{2}p+\beta\right) (1+pf/m)^{\frac{1}{2}(p+m)+\beta}}$$

que es la densidad de una F no centrada con p y m grados de libertad respectivamente y parámetros de no centralización z^2 .

Si $T^2 = N(\bar{x} - \mu)^T S^{-1} (\bar{x} - \mu)$ se basa en una muestra de tamaño N de una $N(\mu, \Sigma)$, entonces $(T^2/n) / ((N-p)/p) = 4(5)$

tiene una distribución F no centrada con p y $N-p$ grados de libertad \rightarrow parámetro de no centralización $N(\mu - \mu_0)^T I^{-1}(\mu - \mu_0) = \chi^2$. La expresión de la densidad de T^2 es:

$$\frac{e^{-\frac{1}{2} z^2}}{(N-1) \Gamma(\frac{1}{2}(N-p))} \sum_{\beta=0}^{\infty} \frac{(z^{1/2})^\beta [t^2/(N-1)]^{\frac{1}{2}p+\beta-1} \Gamma(\frac{1}{2}N+\beta)}{\beta! \Gamma(\frac{1}{2}p+\beta) [1+t^2/(N-1)]^{\frac{1}{2}N+p}}$$

Zang (1938) ha obtenido tablas de la probabilidad de aceptar la hipótesis nula (es decir, la probabilidad del error del tipo II) para varios valores de χ^2 y para niveles de significación 0.05 y 0.01. El número de grados de libertad f_2 que allí aparece es el p aquí considerado [$1(1)8$], y f_2 es $n-p+1$ [$2, 4(1)30, 60, \infty$], el parámetro de no centralización ϕ está relacionado con χ^2 mediante la expresión

$$\phi = \frac{z^2}{\sqrt{p+1}} \quad [1(1)3(1)8].$$

A modo de ejemplo, supongamos que $p=4$, $n-p+1=20$ y que queremos contradecir la hipótesis $\mu=0$ a un nivel 1%. Desearíamos conocer la probabilidad de aceptar la hipótesis nula cuando $\phi = 2.5$ ($z^2 = 31.25$). Dicha probabilidad es 0.227. Si pensamos que la desventaja de aceptar la hipótesis nula cuando N, μ_0, I cumplen que $\chi^2 = 31.25$ es menor que la desventaja de rechazarla cuando es cierta, entonces podemos encontrar favorable aceptar el test en estas condiciones. Sin embargo, si la desventaja del error del tipo I es aproximadamente igual que la del tipo II, parece favorable desecharán la probabilidad del error del tipo II. Para ello, adoptando un nivel $\alpha = 5\%$, la probabilidad de un error del tipo II (para $\phi = 2.5$) es solo 0.048.

Existen también tablas (Emma Lehmer, 1944) que proporcionan ϕ para α dado y para una probabilidad de error del tipo II dada. Estas tablas son útiles para ver qué valor de χ^2 es necesario para hacer la probabilidad de aceptar la hipótesis nula suficientemente baja cuando $\mu \neq 0$. Por ejemplo, si queremos ser capaces de rechazar la hipótesis $\mu=0$ sobre la base de una muestra para unos $\mu \neq \Sigma$ dados, podemos ser capaces de elegir N de manera que $N\mu^T\Sigma^{-1}\mu = \chi^2$ sea suficientemente grande. Alguna veces, la dificultad con estas consideraciones es que normalmente no conocemos los valores de μ y Σ (y por tanto, χ^2) para los cuales queremos que la probabilidad de rechazar tenga un cierto valor.

J. ALGUNAS PROPIEDADES OPTIMAS DEL TEST T^2

Supongamos que queremos contradecir la hipótesis $\mu=0$ sobre la base de N observaciones x_1, \dots, x_N de una $N(\mu, \Sigma)$. Consideremos en primer lugar la clase de los tests basados en estadísticos $A = \sum (x_i - \bar{x})(x_i - \bar{x})^T$ que son invariantes con respecto a transformaciones del tipo $A^* = CAC^T$ y $\bar{x}^* = C\bar{x}$, donde C es no singular. La transformación $x_{\alpha}^* = Cx_{\alpha}$ dejó el problema invariante; esto es, entramos de x_{α}^* contradecir la hipótesis $E(x_{\alpha}^*) = 0$ dado que x_1^*, \dots, x_N^* son N observaciones procedentes de una población normal multivariante. Parece razonable buscar una solución que sea también invariante con respecto a estas transformaciones; es decir, buscaremos una región crítica que no se altere mediante una transformación lineal no singular (la definición de la región sea la misma en diferentes sistemas de coordenadas).

TEOREMA. - Dadas las observaciones x_1, \dots, x_N procedentes de una $N(\mu, \Sigma)$, de todos los tests de $\mu=0$ basados en \bar{x} , $A = \sum (x_i - \bar{x})(x_i - \bar{x})^T$ que son invariantes con respecto a transformaciones del tipo $\bar{x}^* = CR$, $A^* = CAC^T$ (c no singular), el test T^2 es uniformemente más potente.

Demonstración. - Como vimos anteriormente, cualquier test basado en T^2 es invariante. Por otra parte, esta función es la única invariante para la que si $f(\bar{x}, A)$ es invariante, entonces $f(\bar{x}^*, A) = f(C\bar{x}^*, I)$, donde la única coordenada de \bar{x}^* diferente de cero es la primera y su valor es $\sqrt{\bar{x}^T A^T \bar{x}}$ (existe una matriz C , no singular, tal que $C\bar{x} = \bar{x}^*$ y $CAC^T = I$). Así $f(\bar{x}, A)$ depende solo de $\bar{x}^T A^T \bar{x}$. Por tanto un test invariante debe de estar basado en $\bar{x}^T A^T \bar{x}$. Finalmente, podemos aplicar el criterio fundamental de Neyman-Pearson a la distribución de T^2 para encontrar el test uniformemente más potente basado en T^2 , frente a la alternativa simple $\bar{x}^2 = N\mu^T\Sigma^{-1}\mu$. El test uniformemente más potente de $\bar{x}^2 = 0$ es el basado en el cuadrante de las distribuciones de T^2 cuando $\bar{x}^2 = N\mu^T\Sigma^{-1}\mu$ y cuando $\bar{x}^2 > 0$. Dicho test es

Si $T^2 = N(\bar{x} - \mu_0)^T S^{-1} (\bar{x} - \mu_0)$ se basa en una muestra de tamaño N de una $N(\mu, \Sigma)$, entonces $(T^2/n) / ((N-p)/p) = 4(5)$

tiene una distribución F no centrada con p y $N-p$ grados de libertad \rightarrow parámetro de no centralización $N(\mu - \mu_0)^T I^{-1}(\mu - \mu_0) = \chi^2$. La expresión de la densidad de T^2 sería

$$\frac{e^{-\frac{1}{2} z^2}}{(N-1) \Gamma(\frac{1}{2}(N-p))} \sum_{\beta=0}^{\infty} \frac{(z^{1/2})^\beta [t^2/(N-1)]^{\frac{1}{2}p+\beta-1} \Gamma(\frac{1}{2}N+\beta)}{\beta! \Gamma(\frac{1}{2}p+\beta) [1+t^2/(N-1)]^{\frac{1}{2}N+p}}$$

Zang (1938) ha obtenido tablas de la probabilidad de aceptar la hipótesis nula (es decir, la probabilidad del error del tipo II) para varios valores de χ^2 y para niveles de significación 0.05 y 0.01. El número de grados de libertad f_2 que allí aparece es el p aquí considerado [$1(1)8$], y f_2 es $n-p+1$ [$2, 4(1)30, 60, \infty$], el parámetro de no centralización ϕ está relacionado con χ^2 mediante la expresión

$$\phi = \frac{z}{\sqrt{p+1}} \quad [1(1)3(1)8].$$

A modo de ejemplo, supongamos que $p=4$, $n-p+1=20$ y que queremos contrastar la hipótesis $\mu=0$ a un nivel 1%. Desearíamos conocer la probabilidad de aceptar la hipótesis nula cuando $\phi = 2.5$ ($z^2 = 31.25$). Dicha probabilidad es 0.227. Si pensamos que la desventaja de aceptar la hipótesis nula cuando N, μ_0, I cumplen que $z^2 = 31.25$ es menor que la desventaja de rechazarla cuando es cierta, entonces podemos encontrar razonable aceptar el test en estas condiciones. Sin embargo, si la desventaja del error del tipo I es aproximadamente igual que la del tipo II, parece razonable desechar disminuir la probabilidad del error del tipo II. Para ello, adoptando un nivel $\alpha = 5\%$, la probabilidad de un error del tipo II (para $\phi = 2.5$) es solo 0.048.

Existen también tablas (Emma Lehmer, 1944) que proporcionan ϕ para α dado y para una probabilidad de error del tipo II dada. Estas tablas son útiles para ver qué valor del χ^2 es necesario para hacer la probabilidad de aceptar la hipótesis nula suficientemente baja cuando $\mu \neq 0$. Por ejemplo, si queremos ser capaces de rechazar la hipótesis $\mu=0$ sobre la base de una muestra para unos $\mu \neq \Sigma$ dados, podemos ser capaces de elegir N de manera que $N\mu^T\Sigma^{-1}\mu = \chi^2$ sea suficientemente grande. Ahora bien, la dificultad con estas consideraciones es que normalmente no conocemos los valores de μ y Σ (y por tanto, χ^2) para los cuales queremos que la probabilidad de rechazar tenga un cierto valor.

J. ALGUNAS PROPIEDADES OPTIMAS DEL TEST T^2

Supongamos que queremos contrastar la hipótesis $\mu=0$ sobre la base de N observaciones x_1, \dots, x_N de una $N(\mu, \Sigma)$. Consideremos en primer lugar la clase de los tests basados en los estadísticos $A = \sum (x_i - \bar{x})(x_i - \bar{x})^T$ que son invariantes con respecto a transformaciones del tipo $A^* = CAC^T$ y $\bar{x}^* = C\bar{x}$, donde C es no singular. La transformación $x_{ik}^* = Cx_{ik}$ dejó el problema invariante; esto es, entramos de x_{ik}^* contrastamos la hipótesis $E(x_{ik}^*) = 0$ sabiendo que x_1^*, \dots, x_N^* son N observaciones procedentes de una población normal multivariante. Parece razonable buscar una solución que sea también invariante con respecto a estas transformaciones; es decir, buscaremos una regla inicial que no se altere mediante una transformación lineal no singular (la definición de la regla sea la misma en diferentes sistemas de coordenadas).

TEOREMA. - Dadas las observaciones x_1, \dots, x_N procedentes de una $N(\mu, \Sigma)$, de todos los tests de $\mu=0$ basados en \bar{x} , $A = \sum (x_i - \bar{x})(x_i - \bar{x})^T$ que son invariantes con respecto a transformaciones del tipo $\bar{x}^* = C\bar{x}$, $A^* = CAC^T$ (c. no singular), el test T^2 es uniformemente más potente.

Demonstración. - Como vimos anteriormente cualquier test basado en T^2 es invariante. Por otra parte, esta función es la única invariante para la que si $f(\bar{x}, A)$ es invariante, entonces $f(\bar{x}^*, A) = f(\bar{x}^*, I)$, donde la única coordenada de \bar{x}^* diferente de cero es la primera y su valor es $\sqrt{\bar{x}^T A^T \bar{x}}$ (existe una matriz C , no singular, tal que $C\bar{x} = \bar{x}^*$ y $CAC^T = I$). Así $f(\bar{x}, A)$ depende solo de $\bar{x}^T A^T \bar{x}$. Por tanto un test invariante debe de estar basado en $\bar{x}^T A^T \bar{x}$. Finalmente, podemos aplicar el teorema fundamental de Neyman-Pearson a la distribución de T^2 para encontrar el test uniformemente más potente basado en T^2 , frente a la alternativa simple $\bar{x}^2 = N\mu^T\Sigma^{-1}\mu$. El test uniformemente más potente de $\bar{x}^2 = 0$ es el basado en el cuadrante de las distribuciones de T^2 cuando $\bar{x}^2 = N\mu^T\Sigma^{-1}\mu$ y cuando $\bar{x}^2 > 0$. Dicho test es

$$C < e^{-\frac{1}{2} \epsilon^2} \sum_{\alpha=0}^{\infty} \frac{(z^{1/2})^\alpha (t^{\epsilon}/n)^{\frac{1}{2}\epsilon + \alpha - 1} (1+t^{\epsilon}/n)^{-\frac{1}{2}(n+1)+\alpha} \Gamma(\frac{1}{2}(n+1)+\alpha)}{\alpha! \Gamma(\frac{1}{2}\epsilon + \alpha)} / \frac{(t^{\epsilon}/n)^{\frac{1}{2}\epsilon - 1} (1+t^{\epsilon}/n)^{\frac{1}{2}(n+1)} \Gamma(\frac{1}{2}n)}{\Gamma(\frac{1}{2}\epsilon)} =$$

$$= \frac{\Gamma(\frac{1}{2}\epsilon)}{\Gamma(\frac{1}{2}(n+1))} e^{-\frac{1}{2} \epsilon^2} \sum_{\alpha=0}^{\infty} \frac{(z^{1/2})^\alpha \Gamma(\frac{1}{2}(n+1)+\alpha)}{\alpha! \Gamma(\frac{1}{2}\epsilon + \alpha)} \left(\frac{t^{\epsilon}/n}{1+t^{\epsilon}/n} \right)^\alpha.$$

La parte derecha de la desigualdad es una función estrictamente decreciente de $\frac{t^{\epsilon}/n}{1+t^{\epsilon}/n}$ y por tanto de t^{ϵ} . Así pues la desigualdad se reduce a una de la forma $t^2 > k$ para k elegido adecuadamente. Como no depende de la alternativa 2^2 , el test es uniformemente más potente.

DEFINICIÓN. - Una función crítica $\psi(\bar{x}, A)$ es una función con valor entre 0 y 1 (ambos incluidos) tal que $E(\psi(\bar{x}, A)) = \varepsilon$, el nivel de significación, cuando $\mu = 0$.

Un test aleatorizado evita su rechazar la hipótesis con probabilidad $\psi(\bar{x}, B)$, cuando $\bar{x} = x$, $A = B$. Un test no aleatorizado se define cuando $\psi(\bar{x}, A)$ toma únicamente los valores 0 y 1. Utilizando de manera apropiada el lema de Neyman-Pearson para funciones críticas obtenemos el siguiente resultado.

LEMMA. - Sobre la base de las observaciones x_1, \dots, x_N de $N(\mu, \Sigma)$, se toman los test aleatorizados basados en \bar{x} y A que son invariantes con respecto a transformaciones $\bar{x}' = C\bar{x}$ y $A' = CAC'$ (C no singular), el test T^2 es uniformemente más potente.

TEOREMA. - Sobre la base de N observaciones de $N(\mu, \Sigma)$, se toman los test de $\mu = 0$ que son invariantes con respecto a transformaciones $\bar{x}'_\alpha = Cx_\alpha$ (C no singular), el test T^2 es un test uniformemente más potente; es decir, el test T^2 es al menos tan potente como cualquier otro test invariantes.

Demostración. - Sea $\psi(x_1, \dots, x_N)$ una función crítica de un test invariantes. Entonces

$$E(\psi(x_1, \dots, x_N)) = E_{\bar{x}, A} \{ E(\psi(x_1, \dots, x_N) | \bar{x}, A) \}$$

Puesto que \bar{x}, A son estadísticas suficientes para μ y Σ , $E(\psi(x_1, \dots, x_N) | \bar{x}, A)$ depende sólo de \bar{x}, A . El invariantes tiene la misma potencia que $\psi(x_1, \dots, x_N)$. Remata así que cada test en la clase mayor puede ser reemplazado por un test en la clase menor (los que dependen sólo de \bar{x}, A) que tiene la misma potencia. Aplicando el lema anterior se completa la demostración.

TEOREMA. - Dadas las observaciones x_1, \dots, x_N de una $N(\mu, \Sigma)$, se toman los test que $\mu = 0$ basados en \bar{x} y A con potencia dependiendo sólo de $\epsilon^2 = N \mu' \Sigma^{-1} \mu$, el test T^2 es uniformemente más potente.

Demostración. - Puede verse en Anderson pags. 117, 118.

6. EL PROBLEMA DE BEHRENS-FISHER EN EL CASO MULTIVARIANTE

Queremos a dar ahora una solución análoga a la solución de Scheffé (1943) para el problema de Behrens-Fisher.

Sean $\{x_\alpha^{(i)}\}_{\alpha=1, \dots, N_i}$, $i=1, 2$ muestras procedentes de $N(\mu^{(i)}, \Sigma_i)$, $i=1, 2$. Queremos contrastar la hipótesis $\mu^{(1)} = \mu^{(2)}$. La media $\bar{x}^{(1)}$ de la primera muestra se distribuye normalmente con esperanza

$$E(\bar{x}^{(1)}) = \mu^{(1)}$$

y matriz de covarianzas

$$E[(\bar{x}^{(1)} - \mu^{(1)}) (\bar{x}^{(1)} - \mu^{(1)})'] = \frac{1}{N_1} \Sigma_1.$$

Análogamente, para la media de la segunda muestra tenemos

$$E(\bar{x}^{(2)}) = \mu^{(2)}$$

y matriz de covarianzas

$$E[(\bar{x}^{(2)} - \mu^{(2)}) (\bar{x}^{(2)} - \mu^{(2)})'] = \frac{1}{N_2} \Sigma_2.$$

Aquí $\bar{x}^{(1)} - \bar{x}^{(2)}$ tiene media $\mu^{(1)} - \mu^{(2)}$ y matriz de covarianzas $(1/N_1)\Sigma_1 + (1/N_2)\Sigma_2$. Ahora bien, no podemos utilizar la técnica desarrollada anteriormente puesto que

$$\sum_{\alpha=1}^{N_1} (x_\alpha^{(1)} - \bar{x}^{(1)})(x_\alpha^{(1)} - \bar{x}^{(1)})' + \sum_{\alpha=1}^{N_2} (x_\alpha^{(2)} - \bar{x}^{(2)})(x_\alpha^{(2)} - \bar{x}^{(2)})'$$

no tiene la distribución de Wishart con matriz de covarianzas múltiple de $(1/N_1)\Sigma_1 + (1/N_2)\Sigma_2$.

Si $N_1 = N_2 = N$, podemos utilizar el tét T^2 de una manera obvia. Veamos. Sea $y_\alpha = x_\alpha^{(1)} - x_\alpha^{(2)}$ (suponiendo que la numeración de las observaciones en las dos muestras es independiente de las mismas observaciones). Entonces y_α se distribuye normalmente con media $\mu^{(1)} - \mu^{(2)}$ y matriz de covarianzas $\Sigma_1 + \Sigma_2$, e independientemente de y_β ($\beta \neq \alpha$). Sea $\bar{y} = \frac{1}{N} \sum_\alpha y_\alpha = \bar{x}^{(1)} - \bar{x}^{(2)}$, definamos S mediante

$$(N-1)S = \sum_{\alpha=1}^N (y_\alpha - \bar{y})(y_\alpha - \bar{y})' = \sum_{\alpha=1}^N (x_\alpha^{(1)} - x_\alpha^{(2)} - \bar{x}^{(1)} + \bar{x}^{(2)}) (x_\alpha^{(1)} - x_\alpha^{(2)} - \bar{x}^{(1)} + \bar{x}^{(2)})'$$

Entonces

$$T^2 = N \bar{y}' S^{-1} \bar{y}$$

es adecuado para contrastar la hipótesis $\mu_1 = \mu^{(1)} - \mu^{(2)} = 0$ y T^2 tiene la distribución T^2 con $N-1$ grados de libertad. Hay que señalar en este punto que si hubiéramos sabido que $\Sigma_1 = \Sigma_2$ habríamos utilizado un estadístico T^2 con $2N-2$ grados de libertad; hemos pues perdido $N-1$ grados de libertad en la construcción de un tét que es independiente de las dos matrices de covarianzas.

Volvamos nuevamente al caso en que $N_1 \neq N_2$. Por conveniencia supongamos $N_1 < N_2$. Definimos entonces

$$y_\alpha = x_\alpha^{(1)} - \sqrt{\frac{N_1}{N_2}} x_\alpha^{(2)} + \frac{1}{\sqrt{N_1 N_2}} \sum_{\beta=1}^{N_1} x_\beta^{(2)} - \frac{1}{N_2} \sum_{\gamma=1}^{N_2} x_\gamma^{(2)} \quad \alpha = 1, \dots, N_1$$

El valor esperado de y_α será

$$E(y_\alpha) = \mu^{(1)} - \sqrt{\frac{N_1}{N_2}} \mu^{(2)} + \frac{N_1}{\sqrt{N_1 N_2}} \mu^{(2)} - \frac{N_2}{N_2} \mu^{(2)} = \mu^{(1)} - \mu^{(2)}$$

la matriz de covarianzas de y_α es

$$\begin{aligned} E((y_\alpha - E(y_\alpha))(y_\beta - E(y_\beta))') &= E\left[(x_\alpha^{(1)} - \mu^{(1)}) - \sqrt{\frac{N_1}{N_2}}(x_\alpha^{(2)} - \mu^{(2)}) + \frac{1}{\sqrt{N_1 N_2}} \sum_{\gamma=1}^{N_1} (x_\gamma^{(2)} - \mu^{(2)}) - \frac{1}{N_2} \sum_{\gamma=1}^{N_2} (x_\gamma^{(2)} - \mu^{(2)})\right]' \\ &= \left[(x_\beta^{(1)} - \mu^{(1)}) - \sqrt{\frac{N_1}{N_2}}(x_\beta^{(2)} - \mu^{(2)}) + \frac{1}{\sqrt{N_1 N_2}} \sum_{\gamma=1}^{N_1} (x_\gamma^{(2)} - \mu^{(2)})' - \frac{1}{N_2} \sum_{\gamma=1}^{N_2} (x_\gamma^{(2)} - \mu^{(2)})'\right] \\ &= \delta_{\alpha\beta} \Sigma_1 + \frac{N_1}{N_2} \delta_{\alpha\beta} \Sigma_2 + \Sigma_2 \left(-2 \frac{1}{N_2} + \frac{2}{N_2} \sqrt{\frac{N_1}{N_2}} + \frac{N_1}{N_1 N_2} - 2 \frac{N_1}{\sqrt{N_1 N_2} N_2} + \frac{N_2}{N_2^2}\right) \\ &= \delta_{\alpha\beta} (\Sigma_1 + \frac{N_1}{N_2} \Sigma_2) \end{aligned}$$

Así un estadístico apropiado para contrastar la hipótesis $\mu^{(1)} - \mu^{(2)} = 0$, que tiene una distribución T^2 con N_1-1 grados de libertad, es

$$T^2 = N_1 \bar{y}' S^{-1} \bar{y}$$

donde

$$\bar{y} = \frac{1}{N_1} \sum_{\alpha=1}^{N_1} y_\alpha = \bar{x}^{(1)} - \bar{x}^{(2)}$$

$$(N_1-1)S = \sum_{\alpha=1}^{N_1} (y_\alpha - \bar{y})(y_\alpha - \bar{y})' = \sum_{\alpha=1}^{N_1} \left(x_\alpha^{(1)} - \bar{x}^{(1)} - \sqrt{\frac{N_1}{N_2}} (x_\alpha^{(2)} - \frac{1}{N_1} \sum_{\beta=1}^{N_1} x_\beta^{(2)}) \right) \left(x_\alpha^{(1)} - \bar{x}^{(1)} - \sqrt{\frac{N_1}{N_2}} (x_\alpha^{(2)} - \frac{1}{N_1} \sum_{\beta=1}^{N_1} x_\beta^{(2)}) \right)'$$

lo que en términos de $u_\alpha = x_\alpha^{(1)} - \sqrt{N_1/N_2} x_\alpha^{(2)}$, $\alpha = 1, \dots, N_1$, puede escribirse como

$$(N_1 - 1) S = \sum_{\alpha=1}^{N_1} (u_\alpha - \bar{u})(u_\alpha - \bar{u})'$$

dónde $\bar{u} = \frac{1}{N_1} \sum_{\alpha=1}^{N_1} u_\alpha$.

Este procedimiento ha sido sugerido por Scheffé (1943), que utilizó de esta manera el caso univariante. Demostró Scheffé que en dicho caso, esta técnica daba los intervalos de confianza más pequeños utilizando la t de Student. La ventaja del método estaba en el hecho de utilizar $\bar{x}^{(1)} - \bar{x}^{(2)}$, que es el estadístico más importante para contrastar hipótesis acerca de $\mu^{(1)} - \mu^{(2)}$. El sacrificio de observaciones a la hora de estimar la matriz de covarianzas no es demasiado importante. La extensión del método de Scheffé al caso multivariante se debe a Bennett (1951).

El método es generalizable a situaciones con más de dos poblaciones. Sean $\{x_\alpha^{(i)}\}_{\alpha=1}^{N_i}$, $i=1, \dots, q$ muestras provenientes de $N(\mu^{(i)}, \Sigma_i)$, respectivamente. Consideremos la siguiente hipótesis

$$\sum_{i=1}^q \beta_i \mu^{(i)} = \mu.$$

Dónde los β_i son balances dados, al igual que el vector μ . Si las N_i son distintas, sea N_2 la menor de ellas.

Definimos

$$y_\alpha = \beta_1 x_\alpha^{(1)} + \sum_{i=2}^q \beta_i \sqrt{\frac{N_i}{N_1}} \left(x_\alpha^{(i)} - \frac{1}{N_1} \sum_{\alpha=1}^{N_1} x_\alpha^{(i)} + \frac{1}{\sqrt{N_1 N_i}} \sum_{\alpha=1}^{N_1} x_\alpha^{(i)} \right).$$

Entonces

$$E(y_\alpha) = \beta_1 \mu^{(1)} + \sum_{i=2}^q \beta_i \sqrt{\frac{N_i}{N_1}} \left(\mu^{(i)} - \frac{1}{N_1} N_1 \mu^{(i)} + \frac{N_i}{\sqrt{N_1 N_i}} \mu^{(i)} \right) = \sum_{i=1}^q \beta_i \mu^{(i)}.$$

y

$$E(y_\alpha - E(y_\alpha)) (y_\beta - E(y_\beta))' = \delta_{\alpha\beta} \left(\sum_{i=1}^q \frac{\beta_i^2 N_i}{N_1} \Sigma_i \right).$$

Sean \bar{y} y S definidas mediante

$$\bar{y} = \frac{1}{N_1} \sum_{\alpha=1}^{N_1} y_\alpha = \sum_{i=1}^q \beta_i \bar{x}^{(i)}, \quad \text{con} \quad \bar{x}^{(i)} = \frac{1}{N_i} \sum_{\alpha=1}^{N_i} x_\alpha^{(i)},$$

$$(N_1 - 1) S = \sum_{\alpha=1}^{N_1} (y_\alpha - \bar{y})(y_\alpha - \bar{y})'.$$

Entonces

$$T^2 = N_1 (\bar{y} - \mu)^T S^{-1} (\bar{y} - \mu)$$

es un estadístico apropiado para contrastar la hipótesis propuesta, cuando la hipótesis cierta. Este estadístico tiene una distribución T^2 con $N_1 - 1$ grados de libertad. Mediante un cambio de tipo

$$u_\alpha = \sum_{i=1}^q \beta_i \sqrt{\frac{N_i}{N_1}} x_\alpha^{(i)} \quad \alpha = 1, \dots, N_1$$

S puede expresar de la forma

$$(N_1 - 1) S = \sum_{\alpha=1}^{N_1} (u_\alpha - \bar{u})(u_\alpha - \bar{u})'.$$

Para terminar un último problema que puede resolverse mediante este procedimiento es el de contrastar la hipótesis de que dos subvectores de un determinado vector normal multivariante tienen igual media. Sea

$$x = \begin{pmatrix} x^{(1)} \\ x^{(2)} \end{pmatrix}$$

distribuido normalmente con media

$$\mu = \begin{pmatrix} \mu^{(1)} \\ \mu^{(2)} \end{pmatrix}$$

y matriz de covarianzas

$$I = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}.$$

Supongamos que $x^{(1)}$ y $x^{(2)}$ tienen cada uno q componentes. Entonces $x^{(1)} - x^{(2)}$ se distribuye normalmente con media $\mu^{(1)} - \mu^{(2)}$ y matriz de covarianzas

$$E((x^{(1)} - \mu^{(1)}) - (x^{(2)} - \mu^{(2)}))((x^{(1)} - \mu^{(1)}) - (x^{(2)} - \mu^{(2)}))^T = \Sigma_{11} - \Sigma_{21} - \Sigma_{12} + \Sigma_{22}.$$

Para contrastar la hipótesis $\mu^{(1)} = \mu^{(2)}$ utilizaremos el estadístico T^2 definido mediante:

$$T^2 = N(\bar{x}^{(1)} - \bar{x}^{(2)})^T (\Sigma_{11} - \Sigma_{21} - \Sigma_{12} + \Sigma_{22})^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)})$$

donde la media muestral y la matriz de covarianzas muestral han sido preciosas de forma similar a como lo han sido μ y Σ .

EJEMPLOS

- ① En una investigación de las respuestas al test de Wechsler para la inteligencia de adultos aplicado a hombres y mujeres de edad avanzada se obtuvieron las siguientes medias para las respuestas verbal y de computamiento

$$\begin{bmatrix} \bar{x}_v \\ \bar{x}_c \end{bmatrix} = \begin{bmatrix} 55.24 \\ 34.97 \end{bmatrix}$$

teniendo la muestra de un tamaño $N=101$ y los sujetos de edad comprendidos entre los 60, 64 años. La matriz de covarianzas muestral de las respuestas fue

$$\Sigma = \begin{bmatrix} 210.54 & 126.99 \\ 126.99 & 119.68 \end{bmatrix}$$

Desarrollamos contrastar, a un nivel $\alpha=0.01$ la hipótesis nula de que las observaciones provienen de una población con vector media

$$\mu_0 = \begin{bmatrix} 60 \\ 50 \end{bmatrix}.$$

El test está basado en la aplicación del estadístico T^2 , cuyo valor vendría dado por

$$T^2 = N(\bar{x} - \mu_0)^T \Sigma^{-1} (\bar{x} - \mu_0) = 101. [55.24 - 60, 34.97 - 50] \begin{bmatrix} 0.01319 & -0.01400 \\ -0.01400 & 0.02321 \end{bmatrix} \begin{bmatrix} 55.24 - 60 \\ 34.97 - 50 \end{bmatrix} = 357.43$$

el valor $[T^2/(N-1)]^{[(N-p)/p]}$ es una F de Snedecor con p y $N-p$ grados de libertad, por tanto

$$F = \frac{357.43}{100} \cdot \frac{99}{2} = 176.93$$

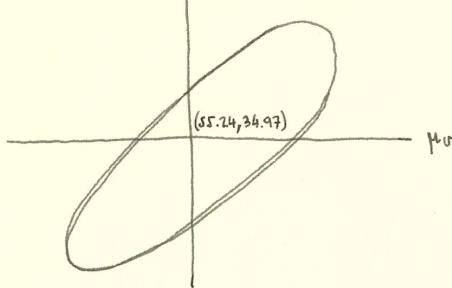
como $F_{0.01, 2, 99} \approx 4.08$, y $F > F_{0.01, 2, 99}$ rechazamos la hipótesis formulada. A la vista de los resultados obtenidos cabe pensar que la población origen de estos datos debe poseer un vector media menor que el postulado en H_0 .

Podemos también hacer uso de T^2 para obtener una regla al 99% de confianza para el vector media de la población. Rechazaremos el valor de $F_{0.01, 2, 99}$ que podemos obtener por interpolación entre los de $F_{0.01, 2, 60}$, $F_{0.01, 2, 120}$, lo que da para $F_{0.01, 2, 99}$ un valor 4.83.

La ellipse de confianza rendida dada por la ecuación

μ_C

$$1.33 (\mu_V - 55.24)^2 - 2.83 (\mu_V - 55.24)(\mu_C - 34.97) + 2.34 (\mu_C - 34.97)^2 \leq 9.76$$



- ② Cuarenta y nueve ancianos que participaron en un estudio interdisciplinario del envejecimiento humano fueron clasificados en dos categorías de diagnóstico, "factor social presente" y "factor social ausente", sobre la base de un ítem examen psiquiátrico. La escala de inteligencia de adultos de Wechsler fue administrada a todos los sujetos por un investigador independiente, y ciertos subtests mostraron grandes diferencias entre los dos grupos. A la vista de estos resultados queremos entertain la hipótesis de que los grupos provienen de una misma población.

Los datos muestrales se recogen en la siguiente tabla (valores medios)

Sustest	Grupo	
	Factor social ausente $N_1 = 37$	Factor social $N_2 = 12$
Información	12.57	8.75
Semilleridades	9.57	5.33
Aritmética	11.49	8.50
Figuras complejas	7.97	4.75

La matriz de covarianzas compensada viene dada por

$$S = \begin{bmatrix} 11.2583 & 9.4042 & 7.1489 & 3.3830 \\ 9.4042 & 13.5318 & 7.3830 & 2.5532 \\ 7.1489 & 7.3830 & 11.3744 & 2.6170 \\ 3.3830 & 2.5532 & 2.6170 & 5.8085 \end{bmatrix}$$

El valor de T^2 para dos muestras, en este caso, vale

$$T^2 = \frac{N_1 N_2}{N_1 + N_2} (\bar{x}_1 - \bar{x}_2)' S^{-1} (\bar{x}_1 - \bar{x}_2) = 22.05$$

y el correspondiente valor de F , es

$$F = \frac{\frac{N_1 + N_2 - p - 1}{(N_1 + N_2 - 2)p}}{T^2} = \frac{44}{47.4} \cdot 22.05 = 5.16.$$

Bajo la hipótesis de igualdad de medias la probabilidad de exceder renegante valor de F más menor que 0.005, por tanto rechazaremos la hipótesis formulada para niveles de significación convencionales del 5% o del 1%.

- ③ Se estudian los cambios de concentración en el plasma de ácidos grasos libres (FFA) y glucosa sangüínea (G) en 12 pacientes esquizofrénicos y 13 voluntarios normales, después de inyecciones intramusculares de insulina. Los cambios se resumen en la siguiente tabla

Cambio medio		
Espirofénicos	Normales	
G, mg.%	-25.6	-31.1
FFA, meq/mililitro	-0.06	-0.15
Matriz de sumas de cuadrados y productos cruzados	$\begin{bmatrix} 3455 & 9.9492 \\ 9.9492 & 0.1105 \end{bmatrix}$	$\begin{bmatrix} 3509 & -3.2408 \\ -3.2408 & 0.0865 \end{bmatrix}$
Matriz de covarianzas "pooled"		$S = \begin{bmatrix} 3.02 & 0.292 \\ 0.292 & 0.00876 \end{bmatrix}$

Bajo el supuesto de que los valores de FFA y G tienen una distribución normal bivariante con una matriz de covarianzas que no se afecta por diagnósticos psiquiátricos, debemos contrastar la hipótesis de que los vectores medios en los sujetos normales y en los espirofénicos son equivalentes. Observamos que la hipótesis de la igualdad de la matriz de covarianzas aparece válida respecto de la diagonal principal de la matriz de covarianzas muestral, aunque no tanto para los términos fuera de ésta, es decir la covarianza entre ambas variables.

El valor de T^2 para esta hipótesis

$$H_0: \mu_1 = \mu_2 = 0$$

Viene dado por $T^2 = 6.03$ y el valor de Fanova es $F = 2.88$. Observamos que este valor está comprendido entre los de $F_{0.1,2,22} = 2.56$ y $F_{0.05,2,22} = 3.44$. Esto significa que a un nivel $\alpha = 0.05$ no rechazaremos la hipótesis nula, mientras que la aceptaremos para un nivel superior $\alpha = 0.1$.

- (4) Los niveles de FFA en sangre se midieron en 15 sujetos normales que se sometieron voluntariamente a revisiones de hipnosis. Durante estas sesiones se les pidió que experimentaran miedo, angustia y celos y se les midió la cantidad (o mejor la cantidad en la concentración) de FFA después de cada una de las situaciones ficticias. Bajo el supuesto de que cada una de estas situaciones produce el mismo grado de cambio, los investigadores descubrieron que no había cambios apreciables entre las diferentes reacciones de stress a las que se sometió a los individuos. Los cambios medios de FFA fueron:

$$\bar{x}_1 = 2.699 \quad \bar{x}_2 = 2.178 \quad \bar{x}_3 = 2.358$$

El problema puede resolverse como un caso particular de los problemas de multivariación presentados. Podemos efectuar el siguiente cambio:

$$y_{i1} = x_{i1} - \bar{x}_{i2} \quad y_{i2} = x_{i1} - \bar{x}_{i3} \quad , \quad i=1, \dots, 15$$

es decir

$$y = \begin{bmatrix} 1 & -1 & 0 \\ 1 & 0 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$$

La hipótesis $H_0: \mu_1 = \mu_2 = \mu_3$ es ahora equivalente a $H_0: C\mu = 0$, donde C es la media de y y μ es la media de x .

La matriz de covarianzas muestral para y es

$$S = \begin{bmatrix} 1.7343 & 1.1666 \\ 1.1666 & 2.7733 \end{bmatrix} \quad ? \quad S^{-1} = \begin{bmatrix} 0.9041 & -0.3382 \\ -0.3382 & 0.5029 \end{bmatrix}$$

El valor de $T^2 = N y S^{-1} y$ viene dado por $T^2 = 2.64$ y el correspondiente valor de $F = 1.24$ y como $F_{0.5,2,13} = 3.80$, aceptaremos la hipótesis formulada, es decir, que los cambios de FFA en los diferentes situaciones de stress son iguales.

Capítulo 5

Clasificación de observaciones

1. EL PROBLEMA DE LA CLASIFICACION

El problema de la clasificación surge cuando un investigador realiza varias medidas sobre un individuo y desea clasificarlo en una de varias categorías sobre la base de estas medidas. El investigador no puede identificar al individuo directamente con una categoría y debe por tanto reunir otras medidas en cuestión. En muchos casos puede suponerse que hay un número finito de categorías o poblaciones a las que el individuo puede pertenecer y cada una de las poblaciones se caracteriza por una distribución de probabilidad de las medidas. Así, un individuo es considerado como una observación aleatoria de una población. La cuestión es: Dado un individuo con ciertas medidas, de qué población proviene?

El problema de la clasificación puede ser considerado como un problema de funciones estadísticas de decisión. Tenemos un cierto número de hipótesis: cada una de las hipótesis es que la distribución de la observación es una dada. Dependiendo de aceptas una de estas hipótesis rechazar las otras. Si solo existen dos poblaciones, nos encontramos ante un problema elemental de contrastar una hipótesis de una distribución específica frente a otra.

En algunos casos, las categorías están especificadas de antemano en el sentido de que la distribución de probabilidad de las medidas es completamente conocida. En otros casos, la forma de cada una de las distribuciones puede ser conocida, pero los parámetros de la distribución deben estimarse a partir de una muestra de la población.

Consideremos un ejemplo de clasificación. Los alumnos que desean ingresar en la universidad son sometidos a una batería de tests; el resto de los resultados es un conjunto de medidas x . El estudiante puede ser miembro de una población que consiste en aquellos estudiantes que están capacitados para sacar adelante con éxito los estudios, posiblemente como 'star', o bien pertenecer a la población de los que no completarán con éxito dichos estudios. El problema es clasificar un estudiante sobre la base de sus resultados en el examen de admisión.

En este capítulo desarrollaremos la teoría de clasificación en términos generales para aplicarla posteriormente a aquellos casos en que se involucran poblaciones con distribución normal.

2. NORMAS PARA UNA BUENA CLASIFICACION

Consideraciones previas. - En la realización de un proceso de clasificación se desea minimizar la probabilidad de mal clasificación, o más específicamente, se desea minimizar, por término medio, los malos efectos de clasificación errónea. Tratemos de precisar más este concepto. Por conveniencia consideraremos el caso de dos categorías. Luego tratarímos el caso general.

Supongamos que un individuo es una observación de una de estas dos poblaciones, Π_1 o Π_2 . La clasificación de una observación depende del vector de medidas $x' = (x_1, \dots, x_p)$ sobre este individuo. Construiremos una regla de manera que si un individuo está clasificado mediante ciertos conjuntos de valores de x_1, \dots, x_p sea clasificado como perteneciente a Π_2 ; si no tiene otros valores sea clasificado como perteneciente a Π_1 .

Podemos considerar una observación como un punto en un espacio p -dimensional. Dividimos al espacio en dos regiones. Si la observación está en R_1 , clasificamos al individuo como de Π_1 , si la observación cae en R_2 lo clasificaremos como de Π_2 .

Siguiendo un procedimiento de este tipo, el investigador puede cometer dos tipos de errores. Clasificar al individuo como de Π_2 cuando realmente procede de Π_1 y viceversa. Recostando conocer la indescriptibilidad relativa de estas dos clases de malclasificación. Designaremos por $G(2/1) > 0$ el índice del primero de los errores y por $G(2/2) > 0$ el otro.

Estos errores pueden venir medida en cualquier tipo de unidades. Como más tarde veremos, lo verdaderamente importante es la relación entre los dos errores.

En la tabla que presentamos a continuación aparecen escritas las anteriores situaciones. Obviamente, un buen procedimiento

		Decisión del estadístico	
		Π_1	Π_2
Población de origen	Π_1	0	$G(2/1)$
	Π_2	$G(1/2)$	0

lo que sigue que minimiza, en algún sentido, el índice de las clasificaciones erróneas.

Caso de dos poblaciones

Veamos a continuación los pasos de definir el coste mínimo. En un caso supongamos que tenemos probabilidadas a priori de ambas poblaciones. Sean q_1 y q_2 las probabilidades de que una observación provenga de las poblaciones H_1 y H_2 respectivamente. Las propiedades probabilísticas de H_i están especificadas mediante una función de distribución. Por comodidad consideremos el caso en que la distribución de probabilidad es absolutamente continua y tiene la función de densidad, aunque el caso discreto requiere resultados muy similares. Sean $p_i(x)$, $i=1,2$ las densidades de probabilidad de las poblaciones H_i , $i=1,2$. Si tenemos una regla R de clasificación en la que asignamos la observación a H_1 , la probabilidad de clasificar correctamente una observación que realmente proviene de H_1 es

$$P(1|1, R) = \int_{R_1} p_1(x) dx,$$

y la probabilidad de mala clasificación de una observación que procede de H_2 es

$$P(2|1, R) = \int_{R_2} p_1(x) dx.$$

Análogamente tendríamos

$$P(2|2, R) = \int_{R_2} p_2(x) dx$$

$$P(1|2, R) = \int_{R_1} p_2(x) dx.$$

Puesto que la probabilidad de extender una observación de H_1 es q_1 , la probabilidad de extender una observación de H_1 y clasificarla incorrectamente es $q_1 \cdot P(2|1, R)$. Análogamente obtendríamos las probabilidades de los tres restantes resultados posibles.

¿Cuál sería la pérdida esperada o el costo medio de mala clasificación? Es la suma de los productos del coste de cada una de las clasificaciones erróneas por la probabilidad de que ocurrir; a saber

$$C(2|1) \cdot P(2|1, R) \cdot q_1 + C(1|2) \cdot P(1|2, R) \cdot q_2$$

Es este costo medio el que se desea minimizar. El decir, se quiere dividir el espacio en dos regímenes R_1 y R_2 de manera que la pérdida esperada sea lo menos posible. Un procedimiento que minimiza la anterior expresión para las q_1 y q_2 dadas es conocido como un procedimiento Bayes.

El otro caso a considerar es aquel en el que no se conocen probabilidades a priori. En este caso la pérdida esperada ni la observación proviene de H_1 o

$$C(2|1) \cdot P(2|1, R) = r(1, R);$$

y para observaciones procedentes de H_2 ,

$$C(1|2) \cdot P(1|2, R) = r(2, R).$$

No sabemos de donde proviene nuestra observación y no conocemos las probabilidades de que pertenezca a una u otra población.

Un procedimiento R es el menos tan bueno como un procedimiento R^* si $r(1, R) \leq r(1, R^*)$ y $r(2, R) \leq r(2, R^*)$. R es mejor que R^* si al menos una de estas desigualdades es estricta. Normalmente no hay procedimientos que sean mejor que cualquier otro o al menos tan bueno como cualquier otro. Un procedimiento R se dice que es admisible si no existe ningún otro que sea mejor; estamos interesados en la clase de los procedimientos admisibles. Demostremos que bajo ciertas condiciones esta clase es la misma que la clase de los procedimientos Bayes. Una clase de procedimientos es completa si para cualquier procedimiento exterior existe uno en la clase que es mejor; una clase es esencialmente completa si para cualquier procedimiento exterior existe uno en la clase que es al menos tan bueno como aquél. Una clase mínima completa (si existe) es una clase completa tal que ningún subconjunto propio es una clase completa; una definición similar puede darse para las clases mínimas esencialmente completas. Bajo ciertas condiciones demostraremos que la clase

admitible es sencillamente completa. Para multiplicar la discusión consideramos que los procedimientos son aquellos en los cuales no difieren solo en conjuntos de probabilidad nula. De hecho, a través de cuantos requeriríamos opiniones que no vierten "excepción hacia de conjuntos de probabilidad nula" aunque no lo hagamos constar explícitamente.

Un principio que usualmente conduce a un procedimiento único es el principio del minimax. Un procedimiento es minimax si la máxima perdida esperada, $R(i, R)$ es un mínimo. De un punto de vista conservador, esto puede ser considerado como un procedimiento óptimo. Un estudio detallado de estos conceptos puede encontrarse en los textos de Wald (1950), Blackwell y Girschick (1954).

3. PROCEDIMIENTOS DE CLASIFICACIÓN EN UNA DE DOS POBLACIONES CUANDO SE CONVIEN LAS DISTRIBUCIONES DE PROBABILIDAD

Probabilidades a priori conocidas

Puesto que conocemos las probabilidades a priori podemos definir la distribución conjunta de las poblaciones y del conjunto de variables observadas. La probabilidad de que una observación provenga de Π_1 y de que cada una de las variables sea menor que la correspondiente componente de y viene dada por

$$\int_{-\infty}^{y_p} \cdots \int_{-\infty}^{y_1} q_1 p_1(x) dx_1 \cdots dx_p$$

Podemos también definir la probabilidad condicional de que una observación provenga de una cierta población dados los valores de las variables observadas. Por ejemplo, la probabilidad condicional de venir de la población Π_1 , dada una observación x ,

$$\frac{q_1 \cdot p_1(x)}{q_1 \cdot p_1(x) + q_2 \cdot p_2(x)}$$

Supongamos por un momento que $C(1/2) = C(2/1) = 1$. Entonces la perdida esperada es

$$q_1 \int_{R_2} p_1(x) dx + q_2 \int_{R_1} p_2(x) dx.$$

Esto es también la probabilidad de una mala clasificación; por tanto, deseamos minimizar la probabilidad de una clasificación errónea.

Para una observación dada x minimizaremos la probabilidad de una mala clasificación asignando la población que tiene una probabilidad condicional mayor. Si

$$\frac{q_1 \cdot p_1(x)}{q_1 \cdot p_1(x) + q_2 \cdot p_2(x)} > \frac{q_2 \cdot p_2(x)}{q_1 \cdot p_1(x) + q_2 \cdot p_2(x)}$$

elijimos la población Π_1 . En cualquier otro caso elegimos Π_2 . Puesto que minimizamos la probabilidad de mala clasificación en cada punto, lo minimizamos sobre el espacio entero. Así, la regla es

$R_1: q_1 \cdot p_1(x) \geq q_2 \cdot p_2(x)$
$R_2: q_1 \cdot p_1(x) < q_2 \cdot p_2(x)$

en caso de igualdad en observación procederemos inmediatamente a una de otras poblaciones. Si $q_1 \cdot p_1(x) + q_2 \cdot p_2(x) = 0$ para un x dado, también en este caso el punto procede asignarse a cualquiera de las regiones.

Problema ahora formalmente que esta regla sea mejor procedimiento. Para cualquier procedimiento $R^* = (R_i^*, R_i^*)$ la probabilidad de mala clasificación es

$$q_1 \int_{R_2^*} p_1(x) dx + q_2 \int_{R_1^*} p_2(x) dx = \int_{R_2^*} [q_1 p_1(x) - q_2 p_2(x)] dx + q_2 \int_{R_2^*} p_2(x) dx.$$

El segundo sumando del segundo miembro es una constante y en cuanto al primer sumando se minimiza si R_2^* incluye los puntos x tales que $q_1 \cdot p_1(x) - q_2 \cdot p_2(x) < 0$, excluye los puntos para los que $q_1 \cdot p_1(x) - q_2 \cdot p_2(x) > 0$. Si suponemos que

$$P \left\{ \frac{p_1(x)}{p_2(x)} = \frac{q_2}{q_1} \mid \Pi_i \right\} = 0 \quad i=1,2$$

entonces el procedimiento Bayes es único excepto para conjuntos de probabilidad nula.

Tenemos con esto un resultado de problema cuando los costos no son iguales e igual a uno. Supongamos ahora que no ocurre así. Se tratará en este caso de minimizar

$$G(2/1) \cdot q_1 \int_{R_2} p_1(x) dx + G(1/2) \cdot q_2 \int_{R_1} p_2(x) dx$$

elijiremos entonces R_1 , R_2 de manera que

$$\boxed{\begin{aligned} R_1: [G(2/1) \cdot q_1] p_1(x) &\geq [G(1/2) \cdot q_2] \cdot p_2(x) \\ R_2: [G(2/1) \cdot q_1] p_1(x) &< [G(1/2) \cdot q_2] \cdot p_2(x) \end{aligned}}$$

puesto que $G(2/1)$, $G(1/2)$ son constantes no negativas. Otra forma de definir R_1 , R_2 sería

$$\boxed{\begin{aligned} R_1: \frac{p_1(x)}{p_2(x)} &\geq \frac{G(1/2) \cdot q_2}{G(2/1) \cdot q_1} \\ R_2: \frac{p_1(x)}{p_2(x)} &< \frac{G(1/2) \cdot q_2}{G(2/1) \cdot q_1} \end{aligned}}$$

TEOREMA. - Si q_1 , q_2 son las probabilidades a priori de extraer una observación de la población Π_1 con probabilidad (densidad) $p_1(x)$ y de la población Π_2 con densidad de probabilidad $p_2(x)$, respectivamente, y si el criterio de mala clasificación de una observación de Π_1 como procedente de Π_2 es $G(2/1)$ y de una observación de Π_2 como procedente de Π_1 es $G(1/2)$, entonces las regiones de clasificación R_1 , R_2 , definidas mediante las anteriores expresiones, minimizan el costo esperado.

Si además

$$P \left\{ \frac{p_1(x)}{p_2(x)} = \frac{q_2 G(1/2)}{q_1 G(2/1)} / \Pi_i \right\} = 0 \quad , i=1,2$$

entonces el procedimiento es único casi por todos partes.

Cuando no se conocen probabilidades a priori

En muchos ejemplos de clasificación el estadístico no puede asignar probabilidades a priori a las dos poblaciones. En este caso tendremos de encontrar la clase de los procedimientos admisibles, es decir, el conjunto de procedimientos que no puede ser mejorado.

Probaremos primero que un procedimiento Bayes es admisible. Sean $R = (R_1, R_2)$ un procedimiento Bayes para q_1 , q_2 dadas; existirá un procedimiento $R^* = (R_1^*, R_2^*)$ tal que $P(1/2, R^*) \leq P(1/2, R)$ y $P(2/1, R^*) \leq P(2/1, R)$ con al menos una desigualdad estricta. Puesto que R es Bayes

$$q_1 \cdot P(2/1, R) + q_2 \cdot P(1/2, R) \leq q_1 \cdot P(2/1, R^*) + q_2 \cdot P(1/2, R^*).$$

Esta desigualdad puede dividirse

$$q_1 [P(2/1, R) - P(2/1, R^*)] \leq q_2 [P(1/2, R^*) - P(1/2, R)].$$

Supongamos que $q_1 > 0$. Entonces si $P(1/2, R^*) \leq P(1/2, R)$, la parte derecha de la desigualdad será menor o igual a 0, por tanto $P(2/1, R) \leq P(2/1, R^*)$. Si $q_2 > 0$, realizando de forma análoga llegamos a que $P(1/2, R) \leq P(1/2, R^*)$. Así R^* no es mejor que R y R es admisible. Si $q_2 = 0$, entonces de la desigualdad obtendremos $0 \leq q_2 [P(1/2, R^*) - P(1/2, R)]$. Para un procedimiento Bayes esto impone que R contiene aquellos x tales que $p_2(x) = 0$. Por tanto $P(1/2, R) = 0$ y si R^* ha de ser mejor que R , deberá venir que $P(1/2, R^*) = 0$. De acuerdo a $P(2/1, R)$ si $P(p_2(x) = 0 / \Pi_1) = 0$, entonces $P(2/1, R) = P(p_2(x) > 0 / \Pi_1) = 1$. Ahora bien si $P(1/2, R^*) = 0$, entonces R^* contiene todos los puntos para los que $p_2(x) = 0$, pero $P(2/1, R^*) = P(R_2^* / \Pi_1) = P(p_2(x) > 0 / \Pi_1) = 1$, y por tanto R^* no es mejor que R .

TEOREMA. - Si $P(p_2(x) = 0 / \Pi_1) = 0$ y $P(p_1(x) = 0 / \Pi_2) = 0$ entonces todo procedimiento Bayes es admisible.

probamos ahora el inverso, es decir, que todo procedimiento admisible Bayes. Supongamos

5(3)

$$P\left\{\frac{p_1(x)}{p_2(x)} = k/\pi_i\right\} = 0, \quad i=1,2; \quad 0 \leq k \leq \infty \quad \left[\frac{p_1(x)}{p_2(x)} = \infty \text{ significa que } p_1(x) = \infty\right].$$

Entonces para cualquier q_2 el procedimiento Bayes es único. Además la función de distribución de $p_1(x)/p_2(x)$ para π_1, π_2 es continua.

Sea R un procedimiento admisible. Entonces existe un K tal que

$$P(2/1, R) = P\left\{\frac{p_1(x)}{p_2(x)} \leq K/\pi_i\right\} = P(2/1, R^*)$$

donde R^* es el procedimiento Bayes correspondiente a $q_2/\pi_2 = K$ [es decir, $q_2 = 1/(1+k)$]. Puesto que R es admisible, tendremos $P(1/2, R) \leq P(1/2, R^*)$. Sin embargo de acuerdo anterior apimosa que R^* es admisible y por tanto $P(1/2, R) \geq P(1/2, R^*)$ y de aquí la igualdad de ambos. Por definición R es un procedimiento Bayes y por la unicidad de los procedimientos debe de ser precisamente R^* .

TEOREMA - Si $P\left\{\frac{p_1(x)}{p_2(x)} = k/\pi_i\right\} = 0, \quad i=1,2; \quad 0 \leq k \leq \infty$, entonces cualquier procedimiento admisible es un procedimiento Bayes.

De acuerdo con lo visto en la demostración de este último teorema la clase de los procedimientos Bayes es completa. Es decir que cada una de las siguientes se trata de una clase minimal completa puesto que coincide con la clase de los procedimientos admisibles.

Consideremos finalmente el procedimiento minimax. Sea $P(i/j, q_2) = P(i/j, R)$, donde R es el procedimiento Bayes correspondiente a q_2 . $P(i/j, q_2)$ es una función continua de q_2 . Así, $P(2/1, q_2)$ varía de 1 a 0 cuando q_2 va de 0 a 1, mientras que $P(1/2, q_2)$ lo hace, al mismo tiempo, de 0 a 1. Existe así pues un valor de q_2 , q_2^* , tal que $P(2/1, q_2^*) = P(1/2, q_2^*)$. Esta es la adicción minimax y es óptima, por cuanto no existe otro procedimiento R^* tal que $\max\{P(2/1, R^*), P(1/2, R^*)\} \leq P(2/1, q_2^*) = P(1/2, q_2^*)$ sea contradicción al hecho de que toda adicción Bayes admisible.

4. CLASIFICACIÓN EN UNA DE DOS POBLACIONES NORMALES MULTIVARIANTES CONVICIDAS

Utilizaremos el procedimiento general denrito anteriormente para el caso de dos poblaciones normales multivariantes con igual matriz de covarianza, a saber, $N(\mu^{(1)}, \Sigma)$ y $N(\mu^{(2)}, \Sigma)$, donde $\mu^{(i)(1)} = (\mu_1^{(i)}, \dots, \mu_p^{(i)})$ es el vector de medias de la i -ésima población ($i=1,2$) y Σ la matriz de covarianzas comunes a ambas poblaciones. La densidad de la población i es

$$p_i(x) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \exp\left[-\frac{1}{2}(x-\mu^{(i)})'\Sigma^{-1}(x-\mu^{(i)})\right].$$

La función de densidad viene dada por

$$\frac{p_1(x)}{p_2(x)} = \frac{\exp\left[-\frac{1}{2}(x-\mu^{(1)})'\Sigma^{-1}(x-\mu^{(1)})\right]}{\exp\left[-\frac{1}{2}(x-\mu^{(2)})'\Sigma^{-1}(x-\mu^{(2)})\right]} = \exp\left[-\frac{1}{2}(x-\mu^{(1)})'\Sigma^{-1}(x-\mu^{(1)}) - (x-\mu^{(2)})'\Sigma^{-1}(x-\mu^{(2)})\right].$$

La regla de clasificación en R_1, R_2 , es el conjunto de x 's para los que este cociente es $\geq k$ (k elegido adecuadamente). Puesto que la función logarítmica es una función monótona creciente, la desigualdad puede ser escrita en términos de sus logaritmos como

$$-\frac{1}{2}\{(x-\mu^{(1)})'\Sigma^{-1}(x-\mu^{(1)}) - (x-\mu^{(2)})'\Sigma^{-1}(x-\mu^{(2)})\} \geq \log k.$$

lo que desarrollando conduce a

$$-\frac{1}{2}\left[x'\Sigma^{-1}x - x'\Sigma^{-1}\mu^{(1)} - \mu^{(1)'}\Sigma^{-1}x + \mu^{(1)'}\Sigma^{-1}\mu^{(1)} - x'\Sigma^{-1}x + x'\Sigma^{-1}\mu^{(2)} + \mu^{(2)'}\Sigma^{-1}x - \mu^{(2)'}\Sigma^{-1}\mu^{(2)}\right] \geq \log k$$

y multiplicando adecuadamente, llegamos a

$$x'\Sigma^{-1}(\mu^{(1)} - \mu^{(2)}) - \frac{1}{2}(\mu^{(1)} + \mu^{(2)})'\Sigma^{-1}(\mu^{(1)} - \mu^{(2)}) \geq \log k.$$

El primer miembro de la desigualdad es conocido como la función discriminante, y es una función lineal de los componentes del vector de las observaciones.

Aplicando resultados anteriores llegamos al siguiente teorema.

TEOREMA - Si π_i tiene una densidad normal multivariante $p_i(x)$, $i=1,2$, los mejores regresos de clasificación vienen dadas por

$$R_1: x^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - \frac{1}{2} (\mu^{(1)} + \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) \geq \log k$$

$$R_2: x^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - \frac{1}{2} (\mu^{(1)} + \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) < \log k.$$

Si las probabilidades a priori q_1 y q_2 son iguales, entonces k viene dado por

$$k = \frac{q_2 C(1/2)}{q_1 C(1/1)}.$$

El caso particular en que las dos posturas son igualmente probables y las mitades son iguales, $k=1$ y $\log k=0$. Entonces la regla de clasificación en π_1 es

$$R_1: x^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) \geq \frac{1}{2} (\mu^{(1)} + \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}).$$

Si no sabemos nada acerca de q_1 y q_2 podemos seleccionar $\log k=C$, sobre la base de igualar las perdidas esperadas debido a malclasificación.

Sea \bar{x} una observación aleatoria. Desearás encontrar la distribución de

$$U = \bar{x}^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - \frac{1}{2} (\mu^{(1)} + \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}),$$

sobre el supuesto de que \bar{x} se distribuye $N(\mu^{(1)}, \Sigma)$ y luego sobre el supuesto de que \bar{x} lo hace $N(\mu^{(2)}, \Sigma)$. Cuando \bar{x} es $N(\mu^{(1)}, \Sigma)$, U es normal con media

$$E_1(U) = \mu^{(1)^T} \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - \frac{1}{2} (\mu^{(1)} + \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) = \frac{1}{2} (\mu^{(1)} - \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}),$$

y varianza

$$\text{var}_1(U) = E_1[(\mu^{(1)} - \mu^{(2)})^T \Sigma^{-1} (\bar{x} - \mu^{(1)}) (\bar{x} - \mu^{(1)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)})] = (\mu^{(1)} - \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}).$$

Sea α la distancia entre las dos posturas, a saber

$$\alpha = (\mu^{(1)} - \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}).$$

Entonces U se distribuye $N(\frac{1}{2}\alpha, \alpha)$ cuando \bar{x} es $N(\mu^{(1)}, \Sigma)$. Si \bar{x} es $N(\mu^{(2)}, \Sigma)$ entonces

$$E_2(U) = \frac{1}{2} (\mu^{(1)} - \mu^{(2)})^T \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) = -\frac{1}{2}\alpha$$

atendiendo la varianza la misma, puesto que solo depende de los momentos de segundo orden de \bar{x} y las mitades en ambos casos. Así, U se distribuye $N(-\frac{1}{2}\alpha, \alpha)$ en este segundo caso.

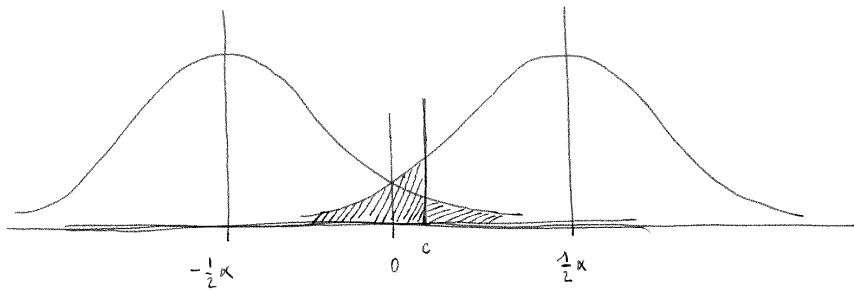
La probabilidad de malclasificación, si la observación proviene de π_1 , es

$$P(2/1) = \int_{-\infty}^{\frac{C}{2}} \frac{1}{\sqrt{2\pi}\alpha} e^{-\frac{1}{2}(z-\frac{1}{2}\alpha)^2/\alpha} dz = \int_{-\infty}^{(C-\frac{1}{2}\alpha)/\sqrt{\alpha}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2} dy$$

y la probabilidad de mala clasificación cuando la observación proviene de π_2 es

$$P(1/2) = \int_C^{\infty} \frac{1}{\sqrt{2\pi}\alpha} e^{-\frac{1}{2}(z+\frac{1}{2}\alpha)^2/\alpha} dz = \int_{(C+\frac{1}{2}\alpha)/\sqrt{\alpha}}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2} dy$$

Otras probabilidades aparecen representadas, en la figura de la página siguiente, como las partes sombreadas de cada una de las colas siguientes.



Para la estimación minimax elegiremos c de manera que

$$G(1/2) \int_{\frac{c+\frac{1}{2}x}{\sqrt{\lambda}}}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2} dy = G(2/1) \int_{-\infty}^{\frac{(c-\frac{1}{2}x)/\sqrt{\lambda}}{}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2} dy.$$

Término. - Si las poblaciones π_i tienen densidades multivariadas $p_i(x)$, $i=1,2$, la estimación minimax viene dada por aquellas regiones que satisfacen las igualdades del anterior teorema con $\log k = 1$ determinado para que verifique la igualdad anterior, es decir que $G(\cdot/\cdot)$ representan los dos artes de mala clasificación.

Hemos de recordar que si los dos artes $G(\cdot/\cdot)$ son iguales, entonces $c=0 \Rightarrow$ la probabilidad de mala clasificación es

$$\int_{\frac{c}{\sqrt{\lambda_2}}}^{\infty} \frac{1}{\sqrt{2\pi\lambda_2}} e^{-\frac{1}{2}y^2} dy.$$

En caso de estos desiguales, c deberá ser determinado mediante un método aproximado a partir de las tablas de la normal.

Observaremos finalmente que los dos términos que aparecen en expresión que determina P_m y R_m pertenecen al vector

$$\delta = \sum_i c_i \mu^{(i)} - \mu^{(1)}.$$

Es interesante recordar que $x' \delta$ es la función lineal que maximiza

$$\frac{[E_1(x'd) - E_2(x'd)]^2}{\text{var}(x'd)}$$

para todos los puntos elementales de d . El numerador de este cociente es

$$(1) \quad [\mu^{(1)'d} - \mu^{(2)'d}]^2 = d' [(\mu^{(1)} - \mu^{(2)}) (\mu^{(1)} - \mu^{(2)})'] d$$

mientras el denominador

$$(2) \quad d' E[(x - E(x)) (x - E(x))'] d = d' \Sigma d.$$

Queremos maximizar (1) manteniendo (2) constante. Si λ es un multiplicador de Lagrange, estamos buscando el máximo de

$$d' [(\mu^{(1)} - \mu^{(2)}) (\mu^{(1)} - \mu^{(2)})'] d - \lambda (d' \Sigma d - 1).$$

Derivando respecto a los componentes de d e igualando a cero obtendremos

$$2 [(\mu^{(1)} - \mu^{(2)}) (\mu^{(1)} - \mu^{(2)})'] d = 2 \lambda \Sigma d.$$

Puesto que $(\mu^{(1)} - \mu^{(2)})' d$ es un escalar, K , escribimos la anterior igualdad como

$$\mu^{(1)} - \mu^{(2)} = \frac{\lambda}{K} \Sigma d$$

y la estimación es proporcional a δ .

Sustituimos finalmente que si tenemos una muestra de tamaño N de cada una de las poblaciones π_1 y π_2 , podemos utilizar la media muestral y clasificarnos como procedente de $N[\mu^{(1)}, \frac{1}{N} \Sigma]$ o $N[\mu^{(2)}, \frac{1}{N} \Sigma]$.

5. CLASIFICACION EN UNA DE DOS POBLACIONES NORMALES MULTIVARIANTES CUANDO LOS PARAMETROS SON ESTIMADOS

El criterio de clasificación. - Hasta ahora hemos supuesto que las poblaciones eran conocidas exactamente. En muchas de las aplicaciones de esta teoría las poblaciones no son conocidas, pero deben ser inferidas a partir de las muestras, una de cada población. Nos ocuparemos a continuación del caso en que tenemos una muestra de cada una de las poblaciones, ambas normales multivariantes, y deseamos utilizar esta información para clasificar otras observaciones como provenientes de una de las dos poblaciones.

Supongamos que tenemos una muestra $x_1^{(1)} \dots x_{N_1}^{(1)}$ de $N(\mu^{(1)}, \Sigma)$ y una muestra $x_1^{(2)} \dots x_{N_2}^{(2)}$ de $N(\mu^{(2)}, \Sigma)$. La mejor estimación de $\mu^{(1)}$ es $\bar{x}^{(1)} = \frac{1}{N_1} \sum x_\alpha^{(1)}$, de $\mu^{(2)}$ es $\bar{x}^{(2)} = \frac{1}{N_2} \sum x_\alpha^{(2)}$, la Σ es S definida mediante

$$(N_1 + N_2 - 2) S = \sum_1^{N_1} (x_\alpha^{(1)} - \bar{x}^{(1)}) (x_\alpha^{(1)} - \bar{x}^{(1)})' + \sum_1^{N_2} (x_\alpha^{(2)} - \bar{x}^{(2)}) (x_\alpha^{(2)} - \bar{x}^{(2)})'.$$

Sustituimos estos valores por los correspondientes parámetros en la expresión obtenida anteriormente para obtener

$$x' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) = \frac{1}{2} (\bar{x}^{(1)} + \bar{x}^{(2)})' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}).$$

El primer término de esta suma es la función discriminante basada en dos muestras [propuesta por Fisher (1936)]. Es una función lineal que tiene la mayor "variancia entre muestras" relativamente a "variancia dentro de las muestras". La idea es utilizar la anterior expresión como criterio de clasificación de la misma forma a como fue utilizada en el caso de conocer los parámetros de las poblaciones.

Cuando las poblaciones eran conocidas, reargumentaba que el criterio de clasificación es el mejor en el sentido de que minimizaba la pérdida esperada en riesgo de probabilidad a priori conocidas y generó la clase de procedimientos admisibles cuando las probabilidades a priori no son conocidas. Ahora no podemos justificarnos en el mismo sentido. Sin embargo, para intuitivamente razonable que el criterio proporciona buenas resultados. Este criterio sera indicado en un punto posterior.

Supongamos que tenemos una muestra $x_1 \dots x_N$ de una u otra población, N_1 o N_2 y deseamos llevar a cabo una clasificación como un todo y no elemento a elemento. Definimos entonces S como

$$(N_1 + N_2 + N - 3) S = \sum_1^{N_1} (x_\alpha^{(1)} - \bar{x}^{(1)}) (x_\alpha^{(1)} - \bar{x}^{(1)})' + \sum_1^{N_2} (x_\alpha^{(2)} - \bar{x}^{(2)}) (x_\alpha^{(2)} - \bar{x}^{(2)})' + \sum_1^N (x_\alpha - \bar{x}) (x_\alpha - \bar{x})'$$

donde

$$\bar{x} = \frac{1}{N} \sum_1^N x_\alpha.$$

Bahnes el criterio es

$$[\bar{x} - \frac{1}{2} (\bar{x}^{(1)} + \bar{x}^{(2)})]' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}).$$

Puede demostrarse que a mayores tales de N , menores son las probabilidades de mala clasificación.

La distribución del criterio. - Sea

$$V = \bar{x}' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) - \frac{1}{2} (\bar{x}^{(1)} + \bar{x}^{(2)})' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) = [\bar{x} - \frac{1}{2} (\bar{x}^{(1)} + \bar{x}^{(2)})]' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)})$$

con $\bar{x}, \bar{x}^{(1)}, \bar{x}^{(2)}$, S aleatorios.

La distribución de V es extremadamente complicada. Depende de los tamaños de las muestras y de los ratios determinados de $\bar{x}_\alpha^{(1)}$, $\bar{x}_\alpha^{(2)}$. Sean ahora

$$Z = \bar{x} - \frac{1}{2} (\bar{x}^{(1)} + \bar{x}^{(2)})$$

$$Y = \bar{x}^{(1)} - \bar{x}^{(2)},$$

entonces

$$V = Z' S^{-1} Y.$$

La esperanza de Y es $\mu^{(1)} - \mu^{(2)}$ y la matriz de covarianzas es $[1/N_1 + 1/N_2] \Sigma$. Z se distribuye normalmente con media

$$E_1(z) = \frac{1}{2} (\mu^{(1)} - \mu^{(2)})$$

si Σ procede de Π_1 , y

$$E_2(z) = \frac{1}{2} (\mu^{(2)} - \mu^{(1)})$$

si Σ procede de Π_2 . En ambos casos la matriz de covarianzas es $[1 + 1/4N_1 + 1/4N_2] \Sigma$. La matriz de covarianzas entre \bar{x} y \bar{z}

$$= \left(\frac{1}{2N_1} + \frac{1}{2N_2} \right) \Sigma.$$

Si $N_1 = N_2$ esta matriz de covarianzas es nula. En este caso se ve fácilmente que la distribución de V para Σ procedente de Π_1 es la misma que la de $-V$ para Σ procedente de Π_2 . Así, si $V \geq 0$ es la regla de clasificación en Π_2 , la probabilidad de clasificar erróneamente a \bar{z} cuando proviene de Π_1 es igual a la probabilidad de hacerlo igualmente mal cuando proviene de Π_2 .

La distribución de V ha sido estudiada por Anderson, Stigler y Wald.

La distribución asintótica del criterio. - En el caso de grandes muestras para ambas poblaciones podemos aplicar la teoría de la distribución límite. Puesto que $\bar{x}^{(1)}$ es la media de la muestra con N_1 variables independientes (observaciones muestrales) todas ellas con distribución $N(\mu^{(1)}, \Sigma)$, sabemos que

$$\lim_{N_1 \rightarrow \infty} \bar{x}^{(1)} = \mu^{(1)} \quad (p).$$

análogamente

$$\lim_{N_2 \rightarrow \infty} \bar{x}^{(2)} = \mu^{(2)} \quad (p)$$

$$\lim S = \Sigma \quad (p)$$

cuando N_1, N_2 o ambos tienden a ∞ . De esta última igualdad se obtiene

$$\lim S^{-1} = \Sigma^{-1} \quad (p)$$

límite en probabilidad

puesto que los ~~productos~~ de sumas, diferencias, productos y cocientes de variables aleatorias con las sumas, productos y cocientes de los límites en probabilidad siempre que el límite de cada denominador sea diferente de cero. Otros, aplicando todo esto

$$\lim_{N_1, N_2 \rightarrow \infty} S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) = \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) \quad (p)$$

$$\lim_{N_1, N_2 \rightarrow \infty} (\bar{x}^{(1)} + \bar{x}^{(2)})' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) = (\mu^{(1)} + \mu^{(2)})' \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) \quad (p).$$

Se origina que la distribución asintótica de V es la distribución de χ^2 estudiada en el párrafo anterior. Para muestras suficientemente grandes de Π_1 y Π_2 podemos utilizar el criterio como si conociersemos exactamente las poblaciones manteniendo sólo un pequeño error.

TÉOREMA. - Sea V definido como ante. La distribución asintótica de V cuando $N_1 \rightarrow \infty$, $N_2 \rightarrow \infty$ es $N\left(\frac{1}{2}\alpha, \alpha\right)$ si Σ procede de la población Π_1 y $N(-\frac{1}{2}\alpha, \alpha)$ si Σ procede de la población Π_2 . Donde $\alpha = (\mu^{(1)} - \mu^{(2)})' \Sigma^{-1} (\mu^{(1)} - \mu^{(2)})$.

Otra derivación del criterio. - Una extensión convenientemente nomenclática del criterio es el uso de la regresión de una variable tóxica dada por Fisher en su trabajo de 1936. Sea

$$y_\alpha^{(1)} = \frac{N_2}{N_1 + N_2}, \quad \alpha = 1, \dots, N_2 \quad , \quad y_\alpha^{(2)} = \frac{-N_1}{N_1 + N_2} \quad \alpha = 1, \dots, N_2.$$

Se busca de minimizar la regresión sobre las variables $x_\alpha^{(1)}$ eligiendo b de manera que se minimice

$$\sum_{l=1}^2 \sum_{\alpha=1}^{N_l} [y_{\alpha}^{(l)} - b^T (x_{\alpha}^{(l)} - \bar{x})]^2$$

donde

$$\bar{x} = [N_1 \bar{x}^{(1)} + N_2 \bar{x}^{(2)}] / (N_1 + N_2)$$

Las "ecuaciones normales" son

$$\sum_{l=1}^2 \sum_{\alpha=1}^{N_l} (x_{\alpha}^{(l)} - \bar{x})(x_{\alpha}^{(l)} - \bar{x})^T b = \sum_{l=1}^2 \sum_{\alpha=1}^{N_l} y_{\alpha}^{(l)} (x_{\alpha}^{(l)} - \bar{x}) = \frac{N_1 N_2}{N_1 + N_2} [(\bar{x}^{(1)} - \bar{x}) - (\bar{x}^{(2)} - \bar{x})] = \frac{N_1 N_2}{N_1 + N_2} (\bar{x}^{(1)} - \bar{x}^{(2)})$$

la matriz que multiplica a b puede resumir como

$$\begin{aligned} \sum_{l=1}^2 \sum_{\alpha=1}^{N_l} (x_{\alpha}^{(l)} - \bar{x})(x_{\alpha}^{(l)} - \bar{x})^T &= \sum_{l=1}^2 \sum_{\alpha=1}^{N_l} (x_{\alpha}^{(l)} - \bar{x}^{(l)})(x_{\alpha}^{(l)} - \bar{x}^{(l)})^T + N_1 (\bar{x}^{(1)} - \bar{x})(\bar{x}^{(1)} - \bar{x})^T + N_2 (\bar{x}^{(2)} - \bar{x})(\bar{x}^{(2)} - \bar{x})^T = \\ &= \sum_{l=1}^2 \sum_{\alpha=1}^{N_l} (x_{\alpha}^{(l)} - \bar{x}^{(l)})(x_{\alpha}^{(l)} - \bar{x}^{(l)})^T + \frac{N_1 N_2}{N_1 + N_2} (\bar{x}^{(1)} - \bar{x}^{(2)})(\bar{x}^{(1)} - \bar{x}^{(2)})^T. \end{aligned}$$

De definito las anteriores ecuaciones normales pueden resumir como

$$G b = (\bar{x}^{(1)} - \bar{x}^{(2)}) \left[\frac{N_1 N_2}{N_1 + N_2} - \frac{N_1 N_2}{N_1 + N_2} (\bar{x}^{(1)} - \bar{x}^{(2)})^T b \right]$$

donde

$$G = \sum_{l=1}^2 \sum_{\alpha=1}^{N_l} (x_{\alpha}^{(l)} - \bar{x}^{(l)})(x_{\alpha}^{(l)} - \bar{x}^{(l)})^T.$$

puesto que $(\bar{x}^{(1)} - \bar{x}^{(2)})^T b$ es un escalar, vemos que la solución b de la anterior expresión se proporcional a $S^{-1}(\bar{x}^{(1)} - \bar{x}^{(2)})$.

El criterio de la razón de verosimilitud. - Otro criterio que puede ser utilizado en la clasificación es el de la razón de verosimilitud

Consideremos que contrastamos la hipótesis nula de que $x, x_1^{(1)}, \dots, x_{N_1}^{(1)}$ son extraídas de $N(\mu^{(1)}, \Sigma)$ y $x_1^{(2)}, \dots, x_{N_2}^{(2)}$ lo son de $N(\mu^{(2)}, \Sigma)$, frente a la alternativa de que $x_1^{(1)}, \dots, x_{N_1}^{(1)}$ pertenecen a $N(\mu^{(1)}, \Sigma)$, mientras que $x, x_1^{(2)}, \dots, x_{N_2}^{(2)}$ lo hacen a $N(\mu^{(2)}, \Sigma)$, con $\mu^{(1)}, \mu^{(2)} \neq \Sigma$ no especificados. Bajo la primera hipótesis los estimadores máximos verosimiles de $\mu^{(1)}, \mu^{(2)}, \Sigma$ son

$$\hat{\mu}_1^{(1)} = (N_1 \bar{x}^{(1)} + x) / (N_1 + 1)$$

$$\hat{\mu}_1^{(2)} = \bar{x}^{(2)}$$

$$\hat{\Sigma}_1 = \frac{1}{N_1 + N_2 + 1} \left[\sum_{\alpha=1}^{N_1} (x_{\alpha}^{(1)} - \hat{\mu}_1^{(1)})(x_{\alpha}^{(1)} - \hat{\mu}_1^{(1)})^T + (x - \hat{\mu}_1^{(1)})(x - \hat{\mu}_1^{(1)})^T + \sum_{\alpha=1}^{N_2} (x_{\alpha}^{(2)} - \hat{\mu}_1^{(2)})(x_{\alpha}^{(2)} - \hat{\mu}_1^{(2)})^T \right]$$

puesto que

$$\begin{aligned} \sum_{\alpha=1}^{N_1} (x_{\alpha}^{(1)} - \hat{\mu}_1^{(1)})(x_{\alpha}^{(1)} - \hat{\mu}_1^{(1)})^T + (x - \hat{\mu}_1^{(1)})(x - \hat{\mu}_1^{(1)})^T &= \sum_{\alpha=1}^{N_1} (x_{\alpha}^{(1)} - \bar{x}^{(1)})(x_{\alpha}^{(1)} - \bar{x}^{(1)})^T + N_1 (\bar{x}^{(1)} - \hat{\mu}_1^{(1)})(\bar{x}^{(1)} - \hat{\mu}_1^{(1)})^T + (x - \hat{\mu}_1^{(1)})(x - \hat{\mu}_1^{(1)})^T = \\ &= \sum_{\alpha=1}^{N_1} (x_{\alpha}^{(1)} - \bar{x}^{(1)})(x_{\alpha}^{(1)} - \bar{x}^{(1)})^T + \frac{N_1}{N_1 + 1} (x - \bar{x}^{(1)})(x - \bar{x}^{(1)})^T \end{aligned}$$

podemos escribir $\hat{\Sigma}_1$ de la forma

$$\hat{\Sigma}_1 = \frac{1}{N_1 + N_2 + 1} \left[G + \frac{N_1}{N_1 + 1} (x - \bar{x}^{(1)})(x - \bar{x}^{(1)})^T \right]$$

donde G es la del párrafo anterior. Bajo los supuestos de la hipótesis alternativa encontramos (por consideraciones de simetría)

que los estimadores máximos verosímiles de los parámetros son

$$\hat{p}_2^{(1)} = \bar{x}^{(1)}$$

$$\hat{p}_2^{(2)} = (N_2 \bar{x}^2 + x) / (N_2 + 1)$$

$$\hat{\Sigma}_2 = \frac{1}{N_1 + N_2 + 1} \left[C + \frac{N_2}{N_2 + 1} (x - \bar{x}^{(1)}) (x - \bar{x}^{(2)})' \right].$$

El centro de la varilla de verosimilitud es, por tanto, la potencia $(N_1 + N_2 + 1)/2$. Síma de

$$\frac{|\hat{\Sigma}_2|}{|\hat{\Sigma}_1|} = \frac{\left| C + \frac{N_2}{N_2 + 1} (x - \bar{x}^{(1)}) (x - \bar{x}^{(2)})' \right|}{\left| C + \frac{N_1}{N_1 + 1} (x - \bar{x}^{(1)}) (x - \bar{x}^{(2)})' \right|}$$

que puede también ser escrita de la forma

$$\frac{1 + \frac{N_2}{N_2 + 1} (x - \bar{x}^{(1)})' C^{-1} (x - \bar{x}^{(2)})}{1 + \frac{N_1}{N_1 + 1} (x - \bar{x}^{(1)})' C^{-1} (x - \bar{x}^{(2)})}$$

la región de clasificación en Π_1 querría en aquellos puntos para los que el criterio anterior es mayor que una cantidad dada.

6. CLASIFICACIÓN EN UNA DE VARIAS POBLACIONES

Consideremos ahora el problema de clasificar una observación en una de varias poblaciones. Extendemos las consideraciones hechas en los apartados anteriores al caso de más de dos poblaciones. Sean Π_1, \dots, Π_m , m poblaciones con funciones de densidad $p_1(x), \dots, p_m(x)$ respectivamente. Desearíamos dividir el espacio de observación en m regiones exhaustivas y mutuamente excluyentes, R_1, \dots, R_m . Si una observación cae en R_i diremos que procede de Π_i . Sean $G(j|i)$ los costes de mala clasificación de una observación que procede de la población Π_i como procedente de Π_j . La probabilidad de esta clasificación es

$$P(j|i, R) = \int_{R_j} p_i(x) dx.$$

Supongamos que tenemos probabilidades a priori de las poblaciones, q_1, \dots, q_m . Entonces la pérdida esperada es

$$\sum_{i=1}^m q_i \left\{ \sum_{\substack{j=1 \\ i \neq j}}^m G(j|i) P(j|i, R) \right\}.$$

Desearíamos elegir R_1, \dots, R_m para hacer mínima esta expresión.

Puesto que tenemos probabilidades a priori para las poblaciones, podemos definir la probabilidad condicional de que una observación proceda de la población Π_i dados estos valores de los componentes del vector x . Esta probabilidad viene dada por

$$\frac{q_i \cdot p_i(x)}{\sum_{k=1}^m q_k \cdot p_k(x)}.$$

Si clasificamos la observación como perteneciente a Π_j , la pérdida esperada es

$$\sum_{\substack{i=1 \\ i \neq j}}^m \frac{q_i \cdot p_i(x)}{\sum_{k=1}^m q_k \cdot p_k(x)} \cdot G(j|i)$$

minimizaremos la pérdida esperada en estos condiciones, si elegimos j de manera que minimice la anterior expresión;

es decir, consideraremos

$$\sum_{\substack{i=1 \\ i \neq j}}^m q_i \cdot p_i(x) G(j|i)$$

para todos los j , seleccionamos aquel j que proporciona el mínimo. (En el caso de igualdad la elección es irrelevante). El procedimiento asigna el punto x a una de las R_j . Siguiendo este procedimiento para cada x , definiremos nuestras regiones R_1, \dots, R_m . El procedimiento de clasificación entra, & clasificar una observación como procedente de Π_j si cae en R_j .

TEOREMA. - Si q_i es la probabilidad a priori de extraer una observación de una población Π_j con densidad $p_i(x)$, $i=1, \dots, m$ & el costo de mal clasificar una observación de Π_i como procedente de Π_j es $G(j/i)$, entonces las regiones de clasificación R_1, \dots, R_m , que minimizan el costo esperado, se definen asignando x a R_k si

$$\sum_{\substack{i=1 \\ i \neq k}}^m q_i \cdot p_i(x) G(k/i) < \sum_{\substack{i=1 \\ i \neq j}}^m q_i \cdot p_i(x) G(j/i), \quad j=1, \dots, m, j \neq k.$$

Si esta desigualdad se verifica para todos los $i \neq k$, excepto para k se dice entre los que verifica la igualdad, el punto en cuestión puede ser asignado a cualquiera de los $m+1$ procedimientos correspondientes.

Si la probabilidad de que se verifique la igualdad, en lugar de la desigualdad satisfecha, es cero para cada k , j bajo Π_i (para cada i), entonces el procedimiento es único para todas las partes.

Veamos ahora este método. Sea

$$h_j(x) = \sum_{\substack{i=1 \\ i \neq j}}^m q_i \cdot p_i(x) G(j/i).$$

La pérdida esperada de un procedimiento R es

$$\sum_{j=1}^m \int_{R_j} h_j(x) dx = \int_R h(x) dx$$

donde $h(x) = h_j(x)$ para x en R_j . Para el procedimiento Bayes deriva en el teorema $h(x) = h^*(x) = \min_i h_i(x)$. Así la diferencia entre la pérdida esperada para cualquier procedimiento R & la de R^* es

$$\int [h(x) - \min_i h_i(x)] dx = \int_R [h(x) - \min_i h_i(x)] dx \geq 0,$$

verificándose la igualdad sólo si $h(x) = \min_i h_i(x)$ para x en R_j , excepto posiblemente de conjuntos de probabilidad cero.

Veamos como aplicar este método en aquella situación para la que $G(j/i) = 1$, $\forall i, j \neq i$. Damos en R_k

$$\sum_{\substack{i=1 \\ i \neq k}}^m q_i \cdot p_i(x) < \sum_{\substack{i=1 \\ i \neq j}}^m q_i \cdot p_i(x) \quad j \neq k.$$

Rstando $\sum_{\substack{i=1 \\ i \neq j \\ i \neq k}}^m q_i \cdot p_i(x)$ de ambas miembros de la desigualdad, tendremos

$$q_j \cdot p_j(x) < q_k \cdot p_k(x) \quad j \neq k.$$

En este caso el punto x está en R_k si k es el número para el que $q_i \cdot p_i(x)$ es un máximo, es decir R_k es la población más probable.

Supongamos ahora que no tenemos probabilidades a priori, entonces no podemos definir una pérdida esperada numérica para un procedimiento de clasificación. Sin embargo, podemos definir una pérdida esperada sobre la condición de que las observaciones provienen de una población dada. La pérdida esperada en las observaciones proviene de Π_i es

$$\sum_{\substack{j=1 \\ j \neq i}}^m G(j/i) \cdot P(j/i, R) = r(i, R)$$

Un procedimiento R es al menos tan bueno como R^* si $r(i, R) \leq r(i, R^*)$, $i=1, \dots, m$; R mejor si al menos

una desigualdad estricta. R es admissible si no hay ningún procedimiento R^* que sea mejor. Una clase de procedimientos \mathcal{R} es completa si para cualquier procedimiento R exterior a la clase existe un procedimiento R^* en la clase que es mejor.

Veamos ahora que un procedimiento Bayes es admissible. Sea R un procedimiento Bayes y R^* otro procedimiento cualquiera.

Puesto que R es Bayes

$$\sum_{i=1}^m q_i \cdot r(i, R) \leq \sum_{i=1}^m q_i \cdot r(i, R^*).$$

Supongamos que $r(i, R^*) \leq r(i, R)$, $i = 1, \dots, m$ y $q_i > 0$. Entonces

$$q_i [r(1, R) - r(1, R^*)] \leq \sum_{i=2}^m q_i [r(i, R) - r(i, R^*)] \leq 0.$$

y $r(1, R^*) \geq r(1, R)$. Análogamente, si $q_j > 0$, $j \neq i$, tenemos $r(j, R) \leq r(j, R^*)$. En definitiva, R^* no puede ser mejor que R y R es admissible.

Tercera M. - Si $q_i > 0$, $i = 1, \dots, m$, entonces R es un procedimiento admissible.

Supongamos ahora que $G(i/j) = 1$, $i \neq j$, y $\{P_i(x) = 0 / \pi_j\} = 0$. Esta última condición implica que las $P_i(x)$ son probabilidades sobre el mismo conjunto (excepto la de conjuntos de probabilidad nula). Supongamos ahora que $q_i = 0$ para $i = 1, \dots, t$ y $q_i > 0$ para $i = t+1, \dots, m$. Entonces para la clase Bayes, R_i ($i = 1, \dots, t$) es vacío (excepto para conjuntos de probabilidad nula) como se comprueba fácilmente de la definición dada para R_i , bajo esta notación particular, anteriormente (se cumple $P_m(x) = 0, \forall x \in R_i$). Se sigue entonces que $r(i, R) = \sum_{j \neq i} P(j/i, R) = 1 - P(i/i, R) = 1$ para $i = 1, \dots, t$. Entonces R_{t+1}, \dots, R_m es una clase Bayes para el problema que asigna a $P_1(x), \dots, P_m(x)$ y q_{t+1}, \dots, q_m . Del teorema que acabamos de comentar se sigue que no hay ningún procedimiento R^* para el que $P(i/i, R^*) = 0$, $i = 1, \dots, t$, que sea mejor que el procedimiento Bayes. Consideremos ahora un procedimiento R^* tal que R^* videya un conjunto de probabilidad distinto de cero tal que $P(1/1, R^*) > 0$. Para que R^* sea mejor que R

$$P(i/i, R) = \int_{R_i} P_i(x) dx \leq \int_{R_i^*} P_i(x) dx = P(i/i, R^*) \quad , \quad i = 1, \dots, m$$

En tal caso, un procedimiento R^{**} donde R_i^{**} es vacío para $i = 1, \dots, t$, $R_i^{**} = R_i^*$, $i = t+1, \dots, m-1$ y $R_m^{**} = R_m^* \cup R_{t+1}^* \cup \dots \cup R_t^*$

daría mejores resultados como

$$P(i/i, R^{**}) = 0 \quad , \quad i = 1, \dots, t$$

$$P(i/i, R^{**}) = P(i/i, R^*) \geq P(i/i, R) \quad , \quad i = t+1, \dots, m-1$$

$$P(m/m, R^{**}) > P(m/m, R^*) \geq P(m/m, R),$$

entonces $(R_{t+1}^{**}, \dots, R_m^{**})$ sería mejor que (R_{t+1}, \dots, R_m) para el problema de decisión sobre los $m-t$ postulados, lo que contradice la discusión precedente.

Tercera M. - Si $G(i/j) = 1$, $i \neq j$ y $\{P_i(x) = 0 / \pi_j\} = 0$, entonces todo procedimiento Bayes es admissible.

Probaremos ahora que los procedimientos admisibles son procedimientos Bayes. Retengamos mucha atención al caso $m=3$. Supongamos que

$$P\left\{\frac{P_i(x)}{P_j(x)} = K / \pi_j\right\} = 0 \quad , \quad i \neq j, \quad 0 \leq K < \infty.$$

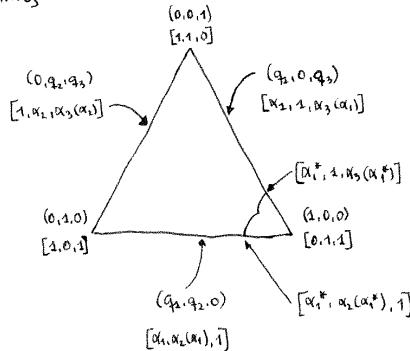
Esto implica que las ~~distribuciones~~ de probabilidad de $P_i(x)/P_j(x)$, para cualquier π_j , son continuas y que la unión de dos de ellas viene, también continua.

Sea $\alpha_i(R) = 1 - P(i/i, R)$ la probabilidad de efectuar una decisión errónea cuando se utiliza el procedimiento R y se muestra en π_i . Cuando R es un procedimiento Bayes, $\alpha_i(R)$ es una función de q_1, q_2, q_3 , a decir $\alpha(q_1, q_2, q_3)$. Es una función continua de q_1, q_2, q_3 ; por ejemplo

$$\alpha(q_1, q_2, q_3) = 1 - P\left\{\frac{P_2(x)}{P_1(x)} \leq \frac{q_1}{q_2}, \frac{P_3(x)}{P_1(x)} \leq \frac{q_1}{q_3} \mid \pi_1\right\},$$

siendo continuas las distribuciones de $\frac{P_2(x)}{P_1(x)}$ y $\frac{P_3(x)}{P_1(x)}$. Es conveniente pensar en (q_1, q_2, q_3) como las coordenadas báxicas de

en punto. los límites



del espacio de tripletes, y los valores de las funciones sobre dichos límites se indican en la figura.

Sea ahora R^* un procedimiento admisible, y sea $\alpha_i(R^*) = \alpha_i^*$. Demostremos que R^* es un procedimiento Bayes. Consideremos la trivialidad del los procedimientos Bayes para los que (q_1, q_2, q_3) dan lugar a $\alpha_i(q_1, q_2, q_3) = \alpha_i^*$. Cuando $q_3 = 0$, tenemos en efecto un problema de dos decisiones y entonces $\alpha_2 = \alpha_2(\alpha_1^*)$ que es al menos de los α_2 dado $\alpha_1 = \alpha_1^*$ (obtenido de los resultados para el caso de las poblaciones); así $\alpha_2(\alpha_1^*) \leq \alpha_2^*$; y $\alpha_3 = 1$. Análogamente, cuando $q_2 = 0$, $\alpha_3 = \alpha_3(\alpha_1^*) \leq \alpha_3^*$ y $\alpha_1 = 1$. El conjunto de puntos (q_1, q_2, q_3) para los que $\alpha_i(q_1, q_2, q_3) = \alpha_i^*$ es una curva continua (1) desde el punto con $[\alpha_1^*, \alpha_2(\alpha_1^*), 1]$ hasta el punto con $[\alpha_1^*, 1, \alpha_3(\alpha_1^*)]$. Puesto que α_2 varía continuamente desde $\alpha_2(\alpha_1^*)$ hasta 1, existe un punto donde $\alpha_2 = \alpha_2^*$. Existe un procedimiento Bayes \bar{R} tal que $\alpha_1(\bar{R}) = \alpha_1^*$ y $\alpha_2(\bar{R}) = \alpha_2^*$. Puesto que \bar{R} es admisible, por el teorema anterior, $\alpha_3(\bar{R}) \leq \alpha_3^*$. Pero puesto que R^* es admisible $\alpha_3(R^*) = \alpha_3^*$. Por la unicidad de los procedimientos Bayes tenemos que $R^* = \bar{R}$.

TEOREMA. - Si $P\left\{\frac{P_i(x)}{P_j(x)} = k \mid \Pi_{k,i}\right\} = 0$ si $j, 0 \leq k < n$, entonces cualquier procedimiento admisible es un procedimiento Bayes.

La demostración del anterior teorema demuestra que la clase de los procedimientos Bayes es completa. Para cualquier procedimiento dado R^* , existe un procedimiento Bayes \bar{R} que es al menos tan bueno (lo que supone la competitividad bivalente). Pero si \bar{R} y R^* son igualmente buenos entonces son el mismo (excepto para conjuntos de probabilidad cero).

TEOREMA. - Si $P\left\{\frac{P_i(x)}{P_j(x)} = k \mid \Pi_{k,i}\right\} = 0$, la clase de los procedimientos Bayes es minimal completa.

Consideremos también ahora la solución minimax. Existe una solución Bayes para la cual $\alpha_1 = \alpha_2 = \alpha_3$. Puesto que el procedimiento es admisible, no existe otro que tenga una menor probabilidad máxima de error (es decir, cada uno de los errores sea menor). Esto proporciona el procedimiento minimax.

Se pueden consultar las bibliografías citadas para completar esta teoría. Añadamos tan sólo que Von Mises (1945) obtuvo la solución del problema minimax por un camino diferente.

7. CLASIFICACIÓN EN UNA DE VARIAS POBLACIONES NORMALES MULTIVARIANTES

Aplicaremos la teoría del anterior párrafo al caso en que cada una de las poblaciones tiene una distribución normal. Supondremos que las medias son diferentes y las matrices de covarianzas coincidentes. Sea $N(\mu^{(i)}, I)$ la distribución de Π_i . Es un principio importante considerar los parámetros. Para estos generales y probabilidades a priori consideradas podemos formar las funciones como las del párrafo anterior y definir las regiones R_j como aquellas constituidas por puntos x tales que la función fuese mínima.

De lo que sigue supondremos que los totales de mala clasificación no iguales. Entonces utilizaremos las funciones

$$U_{jk}(x) = \log \frac{P_j(x)}{P_k(x)} = [x - \frac{1}{2}(\mu^{(i)} + \mu^{(k)})]^T \Sigma^{-1} (\mu^{(i)} - \mu^{(k)}).$$

Si las probabilidades a priori son conocidas, las regiones R_j son definidas por aquellos x que satisfacen

$$R_j: U_{jk}(x) > \log \frac{q_k}{q_j}, \quad k = 1, \dots, m; \quad k \neq j.$$

(1) Al lo largo de cada eje $q_3 = (1-\alpha_2)(1-\alpha_3) \wedge q_2 = k(1-q_3)$, $0 < k < 1$, α_1 siendo continua y monótonamente de 1 a 0. Sea $q_1 = q_1(k)$ el valor de q_1 tal que $\alpha_1 = \alpha_1^*$; entonces $q_1(k)$ es una función continua de k [por la continuidad de $\alpha_1(q_1, q_2, q_3)$ y la monotonía de α_1 como función de q_1 dado q_2 dado].

TEOREMA - Si q_j es la probabilidad a priori de extraer una observación de $\Pi_i = N(\mu^{(i)}, \Sigma)$ ($i=1, \dots, m$) y si los costos de mal clasificación no iguales, entonces las regiones de clasificación R_1, R_2, \dots, R_m , que minimizan el costo operado vienen definidas por la ilustración anterior, siendo $U_{jk}(x)$ definida como ante.

Hay que señalar que cada $U_{jk}(x)$ es la función de clasificación relacionada con las poblaciones j -sima y k -sima, y $U_{jk}(x) = -U_{kj}(x)$. Puesto que se trata de funciones bivariadas, la región R_i está acotada por hipoplano. Si las medias definen un hipoplano $(m-1)$ -dimensional (por ejemplo, si los vectores medias $\mu^{(i)}$ son linealmente independientes y $p \leq m-1$), entonces R_i está acotada por $m-1$ hipoplano.

En el caso en que no se conocen probabilidades a priori, la región R_i viene definida mediante las desigualdades

$$U_{jk}(x) \geq c_j - c_k, \quad k=1, \dots, m; \quad k \neq j$$

Las constantes c_k pueden tomarse nonnegativas. Este conjunto de regiones forman la clase de procedimientos admisibles. Para el procedimiento minimax estas constantes se eligen de manera que $P(j|i, R)$ sean iguales.

Veamos ahora como obtener las probabilidades de una clasificación correcta. Si x es una observación aleatoria, consideremos las variables aleatorias

$$U_{ji} = [x - \frac{1}{2} (\mu^{(i)} + \mu^{(j)})]^\top \Sigma^{-1} (\mu^{(i)} - \mu^{(j)}).$$

Con $U_{ji} = -U_{ij}$. Utilizamos $m(m-1)/2$ funciones de clasificación si las medias definen un hipoplano $(m-1)$ -dimensional. Si Σ procede de Π_j , entonces U_{ji} se distribuye como $N(\frac{1}{2}\alpha_{jii}, \sigma_{jii})$ donde

$$\alpha_{jii} = (\mu^{(i)} - \mu^{(j)})^\top \Sigma^{-1} (\mu^{(i)} - \mu^{(j)}).$$

La covarianza entre U_{ji} y U_{jk} es

$$\alpha_{jki} = (\mu^{(i)} - \mu^{(k)})^\top \Sigma^{-1} (\mu^{(j)} - \mu^{(i)}).$$

Para determinar las constantes c_j consideramos las integrales

$$P(j|i, R) = \int_{c_j - \infty}^{\infty} \cdots \int_{c_j - \infty}^{\infty} f_j du_{ji} - dU_{jji} du_{jji} - du_{ji},$$

donde f_j es la densidad de U_{ji} ($i=1, 2, \dots, m$). ($i \neq j$).

TEOREMA - Si $\Pi_i \sim N(\mu^{(i)}, \Sigma)$, y los costos de mala clasificación no iguales, las regiones de clasificación, R_1, \dots, R_m , que minimizan la máxima probabilidad condicional, están definidas mediante $U_{jk}(x) \geq c_j - c_k$, ($k=1, \dots, m$; $k \neq j$), donde $U_{jk}(x)$ se define como ante. Las constantes c_j se determinan de manera que las integrales dadas en las expresiones de $P(j|i, R)$ sean iguales.

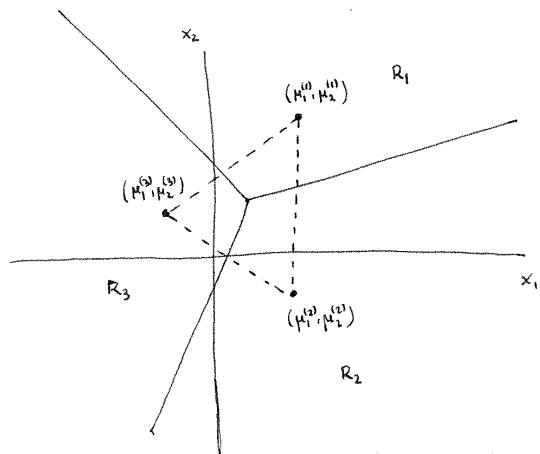
Como un ejemplo consideremos el caso $m=3$. No hay perdida de generalidad si tomamos $p=2$, para dimensiones con mayor p podemos proyectar sobre el plano bidimensional determinado por las medias de las tres poblaciones si no son colineales (a decir, podemos transformar el vector x en U_{12}, U_{13} y $p-2$ otras coordenadas, donde las últimas $p-2$ componentes redistribuyen independientemente de U_{12}, U_{13} con medias cero). Las regiones R_j están determinadas mediante tres rectas, tal como se muestra en la figura.

Si el procedimiento es minimax, los podemos desplazar la recta entre R_2 y R_3 más cerca de $(\mu_1^{(2)}, \mu_2^{(2)})$, la recta entre R_2 y R_3 más cerca de $(\mu_1^{(3)}, \mu_2^{(3)})$ y la recta entre R_3 y R_1 más cerca de $(\mu_1^{(3)}, \mu_2^{(1)})$ y conservar todavía la igualdad $P(1|1, R) = P(2|2, R) = P(3|3, R)$, sin dejar un triángulo que no esté incluido en la región alguna. Por tanto, como las regiones deben cubrir totalmente el espacio, las líneas deben encontrarse en un punto, y la igualdad de probabilidades determina $c_1 = c_2 = c_3$.

Para realizar esto en un caso específico en el que tenemos datos muestrales para los vectores $\mu^{(1)}, \mu^{(2)}, \mu^{(3)}$ y la matriz Σ , consideraremos las tres ($\leq p+1$) distribuciones conjuntas, para los U_{ij} ($j \neq i$). Podremos inicialmente en los datos $c_i = 0$, y utilizando las tablas del Pearson de la normal bivariante calcularemos $P(i|i, R)$, mediante

un método iterativo obteniendo los c_i que más se aproximan a la condición.

La tesis precedente permite de unir los parámetros de las poblaciones. Si no fueran conocidos y si tuviéramos disponible una muestra de cada población, constituiríamos en $U_{ijk}(x)$ cada parámetro por su correspondiente estimación. Sean $x_{i1}^{(1)}, \dots, x_{iN_i}^{(1)}$



las observaciones procedentes de $N(\mu^{(i)}, \Sigma)$, $i=1, \dots, m$. Estimaremos $\mu^{(i)}$ mediante

$$\bar{x}^{(i)} = \frac{1}{N_i} \sum_{\alpha=1}^{N_i} x_{\alpha}^{(i)}$$

y Σ mediante S definida por

$$\left(\sum_{i=1}^m N_i - m \right) S = \sum_{i=1}^m \sum_{\alpha=1}^{N_i} (x_{\alpha}^{(i)} - \bar{x}^{(i)}) (x_{\alpha}^{(i)} - \bar{x}^{(i)})'$$

Entonces, el análogo de $U_{ij}(x)$ es

$$S_{ij}(x) = [x - \frac{1}{2} (\bar{x}^{(i)} + \bar{x}^{(j)})]'^{-1} (\bar{x}^{(i)} - \bar{x}^{(j)}).$$

Si las muestras son identáticas, las distribuciones son diferentes de aquellas de los U_{ij} . No obstante, cuando $N_i \rightarrow \infty$, la distribución conjunta se approxima a la de U_{ij} . Por tanto, para muestras suficientemente grandes podemos utilizar la teoría anterior.

B. UN EJEMPLO DE CLASIFICACIÓN EN UNA DE VARIAS POBLACIONES NORMALES MULTIVARIANTES

Rao (1948) considera tres poblaciones consistentes en la casta de los Brahmin (π_1), la casta de los Artesanos (π_2) y la casta de los Korka (π_3) de la India. Las medidas para cada uno de los individuos de una casta son, la estatura (x_1), altura ventral (x_2), anchura nasal (x_3) y altura nasal (x_4). Las medias de estas variables entre las poblaciones aparecen en la tabla.

	Brahmin π_1	Artesanos π_2	Korka π_3
Estatura (x_1)	164.51	160.53	158.17
Altura ventral (x_2)	86.43	81.47	81.16
Anchura nasal (x_3)	25.49	23.84	21.44
Altura nasal (x_4)	51.24	48.62	46.72

La matriz de covarianzas para todas las poblaciones es

$$\begin{matrix} 1.0000 & 0.5849 & 0.1774 & 0.1974 \\ 0.5849 & 1.0000 & 0.2094 & 0.2120 \\ 0.1774 & 0.2094 & 1.0000 & 0.2910 \\ 0.1974 & 0.2120 & 0.2910 & 1.0000 \end{matrix}$$

Las desviaciones típicas son $\sigma_1 = 5.74$, $\sigma_2 = 3.20$, $\sigma_3 = 1.75$, $\sigma_4 = 3.50$. Suponemos que cada población es normal. Nuestro problema es dividir el espacio de las cuatro variables x_1, x_2, x_3, x_4 en tres regiones de clasificación. Suponemos que los costos de mal clasificación son iguales. Asumiremos a) Un conjunto de regiones bajo el supuesto de que extraer una muestra aleatoria de cada población es igualmente probable ($q_1 = q_2 = q_3 = \frac{1}{3}$), y b) Un conjunto de regiones tales que la mayor probabilidad de mal clasificación sea minimizada (solución minimax).

Calcularemos en primer lugar los coeficientes de $\Sigma^{-1}(\mu^{(1)} - \mu^{(2)})$ y $\Sigma^{-1}(\mu^{(1)} - \mu^{(3)})$. Debemos $\Sigma^{-1}(\mu^{(1)} - \mu^{(3)}) = \Sigma^{-1}(\mu^{(1)} - \mu^{(2)}) - \Sigma^{-1}(\mu^{(2)} - \mu^{(3)})$. Luego calcularemos $\frac{1}{2}(\mu^{(1)} + \mu^{(3)})' \Sigma^{-1}(\mu^{(1)} - \mu^{(3)})$. Los resultados obtenidos con las siguientes funciones discriminantes

$$U_{12}(x) = -0.0708x_1 + 0.4990x_2 + 0.3373x_3 + 0.0867x_4 - 43.13$$

$$U_{13}(x) = 0.0003x_1 + 0.3550x_2 + 1.1063x_3 + 0.1375x_4 - 62.49$$

$$U_{23}(x) = 0.0711x_1 - 0.1440x_2 + 0.7690x_3 + 0.0488x_4 - 19.36.$$

Las otras tres funciones son $U_{21}(x) = -U_{12}(x)$, $U_{31}(x) = -U_{13}(x)$ y $U_{32}(x) = -U_{23}(x)$. Si existen probabilidades a priori γ en las regiones el mejor conjunto de regiones de clasificación es

$$R_1: U_{12}(x) \geq 0, U_{13}(x) \geq 0$$

$$R_2: U_{21}(x) \geq 0, U_{23}(x) \geq 0$$

$$R_3: U_{31}(x) \geq 0, U_{32}(x) \geq 0.$$

Por ejemplo si obtenemos un observación individual x , con $U_{12}(x) \geq 0$ y $U_{13}(x) \geq 0$, lo clasificaremos como Brahmin.

Para encontrar las probabilidades de mal clasificación cuando un individuo es extraído de la población π_i , reescribimos las

Población de x	u	medias	desviaciones típicas	correlación
Π_1	u_{11}	1.491	1.727	0.8658
	u_{13}	3.487	2.641	
Π_2	u_{21}	1.491	1.727	-0.3894
	u_{23}	1.031	1.436	
Π_3	u_{31}	3.187	2.641	0.7983
	u_{32}	1.031	1.436	

Las probabilidades de mala clasificación se obtienen mediante el uso de tablas para la manual bramante. Estas probabilidades son 0.21 para Π_1 , 0.42 para Π_2 y 0.25 para Π_3 . Por ejemplo, si las medidas son bajas sobre un Brahmin, la probabilidad de que sea clasificado como Antezano o Komra es 0.21.

La solución mínima se obtiene sumando las constantes C_1, C_2 y C_3 de manera que las probabilidades de una mala clasificación sean iguales. Las regiones de clasificación son:

$$R_1^1 : u_{11}(x) \geq 0.54, \quad u_{13}(x) \geq 0.29;$$

$$R_2^1 : u_{21}(x) \geq -0.54, \quad u_{23}(x) \geq -0.25;$$

$$R_3^1 : u_{31}(x) \geq -0.29, \quad u_{32}(x) \geq 0.25.$$

La probabilidad de mala clasificación comienza a 0.30. Así, la máxima probabilidad de error ha sido reducida de 0.42 a 0.30.

EJEMPLOS

- ① En un ejemplo del capítulo anterior hablábamos de un grupo de 49 ancianos que provenían de dos poblaciones, la Π_1 , factor renal ausente y la Π_2 , factor renal presente. Recordemos que los datos obtenidos eran

Población		
Factor renal ausente	Factor renal presente	
$\bar{x}_1^{(1)}$	12.87	8.75
$\bar{x}_2^{(1)}$	9.57	5.33
$\bar{x}_3^{(1)}$	11.49	8.50
$\bar{x}_4^{(1)}$	7.97	4.75
$N_1 = 37$		$N_2 = 12$

$$S = \begin{bmatrix} 11.2553 & 9.4042 & 7.1489 & 3.3830 \\ 13.3830 & 7.3830 & 2.5532 & \\ 11.5744 & 2.6170 & & \\ & & 5.8085 & \end{bmatrix}$$

Bueno a calcular la función discriminante lineal para los dos grupos poblacionales. El vector diferencia de medias es

$$(\bar{x}_1 - \bar{x}_2)^T = [3.82, 4.24, 2.99, 3.27]$$

La función discriminante lineal viene dada por

$$y = 0.030x_1 + 0.204x_2 + 0.010x_3 + 0.443x_4.$$

Tenemos que los tests segundo y cuarto, similitud y freguencias completas, respectivamente, dominan la función. Mientras que los tests de información y alfabética tiene una contribución casi despreciable a la función y. De investigaciones posteriores la atención del investigador podría centrarse en aquellos dos como indicadores de la calidad del factor renal.

El término independiente puede obtenerse bien aparte de la expresión

$$\frac{1}{2} (\bar{x}_1 - \bar{x}_2)^T S^{-1} (\bar{x}_1 - \bar{x}_2) = 4.76$$

O bien como el punto medio de los valores medios de la función discriminante en un grupo jato. Así que $\bar{y}_1 = 5.97, \bar{y}_2 = 3.54$

$$\frac{\bar{y}_1 + \bar{y}_2}{2} = 4.76.$$

Si suponemos que nada sabemos acerca de las probabilidades a priori q_1 y q_2 de los pertenecientes Π_1 , Π_2 , respectivamente, en adición tomaremos una hipótesis de estos igualas, $C(1/2) = C(2/1)$. La solución minimax conduce a un punto de discriminación cero, por tanto:

$$R_1: y - \frac{1}{2}(\bar{x}_1 + \bar{x}_2)'S^{-1}(\bar{x}_1 - \bar{x}_2) \geq 0$$

$$R_2: \quad < 0$$

O bien

$$R_1: y(x) \geq 4.76$$

$$R_2: y(x) < 4.76$$

Aplicando esta regla a los individuos de las dos muestras utilizadas obtendremos la siguiente clasificación de los mismos.

		Diagnóstico Positivo		Total
		F.S.A.	F.S.P.	
Clasificación mediante la función discriminante	F.S.A.	29	4	33
	F.S.P.	8	8	16
Total	37	12	49	

La tabla da una medida de la capacidad de la función discriminante lineal para producir el diagnóstico. Obsérvese que la estimación de las probabilidades técnicas de mal clasificación mediante las correspondientes proporciones muestrales no son muy alejadas por cuanto en un caso, $P(2/1)$ ni concuerdan, pero no así en el otro $P(1/2)$. En efecto los valores de α , necesario para invadir la distribución de $U = [\bar{x} - \frac{1}{2}(\mu^{(1)} + \mu^{(2)})]'S^{-1}[\mu^{(1)} - \mu^{(2)}]$, puede estimarse mediante

$$\hat{\alpha} = (\bar{x}^{(1)} - \bar{x}^{(2)})' S^{-1} (\bar{x}^{(1)} - \bar{x}^{(2)}) = 2.42$$

U tiene una distribución $N(\frac{1}{2}\alpha, \alpha)$ si $\bar{x} \in \Pi_1$ y $N(-\frac{1}{2}\alpha, \alpha)$ si $\bar{x} \in \Pi_2$. Utilizando la estimación encontrada para α , tendremos

$$U \approx N\left(\frac{1}{2}\hat{\alpha}, \hat{\alpha}\right) \text{ si } \bar{x} \in \Pi_1$$

$$U \approx N\left(-\frac{1}{2}\hat{\alpha}, \hat{\alpha}\right) \text{ si } \bar{x} \in \Pi_2$$

entonces

$$\boxed{P(2/1) = P(U \leq 0) = P\left(\frac{U - \frac{1}{2}\hat{\alpha}}{\sqrt{\hat{\alpha}}} \leq \frac{-1.21}{\sqrt{2.42}}\right) = P(Z \leq -0.78) = \phi(-0.78) \approx 0.2177}$$

análogamente

$$\boxed{P(1/2) = 0.2177}$$

Las estimaciones, mediante la fórmula de estas cantidades serían

$$\hat{P}(2/1) = \frac{8}{37} \approx 0.2162$$

pero

$$\hat{P}(1/2) = \frac{4}{12} \approx 0.3333 \quad \text{que impone una estimación por exceso.}$$

De este modo que sigue dando una alternativa a este método, para tratar de mejorar las probabilidades de mal clasificación más elevadas.

- ② La información acerca de las frecuencias relativas con que las observaciones de los dos poblaciones son encontradas juntas
 Ser de utilidad su clasificación de estas observaciones mediante funciones discriminantes. Vamos a reclasificar los individuos del ejemplo anterior haciendo uso de una regla Bayes. Necesitaremos para ello probabilidades a priori sobre cada población, por lo que llevaremos a cabo una estimación de las mismas mediante las correspondiente frecuencias relativas dadas con: $\hat{q}_1 = \frac{37}{49}$, $\hat{q}_2 = \frac{12}{49}$. En estos $G(1/2)$ y $G(2/1)$ se manda clasificando los individuos respectivamente.

5 (10)

Si las cosas, la regla de clasificación viene dada por:

$$R_1: y(x) - \frac{1}{2} (\bar{x}_1 + \bar{x}_2)' S^{-1} (\bar{x}_1 - \bar{x}_2) \geq \log \frac{q_2}{q_1}$$

$$R_2: y(x) - \frac{1}{2} (\bar{x}_1 + \bar{x}_2)' S^{-1} (\bar{x}_1 - \bar{x}_2) < \log \frac{q_2}{q_1}$$

$$\log \frac{q_2}{q_1} = \log \frac{12}{37} = -1.126$$

o bien

$$R_1: y(x) \geq 3.634$$

$$R_2: y(x) < 3.634$$

La aplicación de esta regla induce al siguiente cuadro de clasificación:

		Diagnóstico Preoperatorio		
		F.S.A	F.S.P	
Clasificación mediante la función discriminante	F.S.A	37	5	42
	F.S.P.	0	7	7
		37	12	49

La introducción de las probabilidades a priori ha disminuido considerablemente, menos de la mitad, el número de individuos mal clasificados que se obtenía mediante la regla Bayes del ejemplo anterior.

Capítulo 6

La distribución de la matriz de covarianzas muestral y de la varianza muestral generalizada

1. INTRODUCCIÓN

La matriz de covarianzas muestral es $S = [1/(N-1)] \sum_{\alpha} (x_{\alpha} - \bar{x})(x_{\alpha} - \bar{x})'$ y es un estimador de la matriz de covarianzas poblacional Σ . Hemos estudiado anteriormente la distribución de probabilidad de $A = (N-1)S$ para el caso 2×2 , lo que haremos ahora es generalizar este resultado para una matriz A de cualquier orden. Cuando $I=I$, esta distribución es en un sentido una generalización de la distribución χ^2 , la distribución de A ($\text{c.c. } S$), conocida como distribución de Wishart, fundamental en estadística multivariante. Nos ocuparemos de ella y estudiaremos algunas de sus propiedades.

La varianza muestral generalizada se define como $|S|$ y es una especie de medida de la dispersión de la muestra. Su distribución también es considerada en su momento.

2. LA DISTRIBUCIÓN DE WISHART

En este párrafo estudiaremos la distribución de $A = \sum_{\alpha=1}^n (x_{\alpha} - \bar{x})(x_{\alpha} - \bar{x})'$, donde las x_{α} son n independientes, cada una con distribución $N(\mu, \Sigma)$. Como vimos en un capítulo anterior, A se distribuye como $A = \sum_{\alpha=1}^n z_{\alpha} z_{\alpha}'$, donde $n=N-1$ y las z_{α} son n independientes, cada una con distribución $N(0, \Sigma)$. Demostraremos que la distribución (o mejor) la densidad de A , para A definida por

$$\frac{|A|^{\frac{1}{2}(n-p)}}{2^{\frac{1}{2}np} \pi^{p(p-1)/4}} \cdot |\Sigma|^{\frac{1}{2}n} \prod_{i=1}^p \Gamma\left(\frac{1}{2}(n+1-i)\right) \quad (1)$$

Obtenemos en primer lugar (1) para $\Sigma = I$. Utilizaremos aquí repetidamente el siguiente caso especial de un teorema encontrado cuando estudiábamos la distribución del coeficiente de correlación parcial. Si U_{α} son n independientes y W_{α} tiene la distribución $N(PW_{\alpha}, \phi)$, entonces $\sum_{\alpha} U_{\alpha}^2 - \sum_{\alpha} U_{\alpha} W_{\alpha} (\sum_{\alpha} W_{\alpha} W_{\alpha}')^{-1} \sum_{\alpha} U_{\alpha} W_{\alpha}$ se distribuye como $\sum_{\alpha=1}^{n-q} V_{\alpha}^2$, donde q es el número de componentes de W_{α} y las V_{α} son independientes, cada una con una distribución $N(0, \phi)$, e independientemente de $\sum_{\alpha} U_{\alpha} W_{\alpha} (\sum_{\alpha} W_{\alpha} W_{\alpha}')^{-1}$. En particular si $p=1$, entonces $\sum_{\alpha} U_{\alpha}^2 - \sum_{\alpha} U_{\alpha} W_{\alpha} (\sum_{\alpha} W_{\alpha} W_{\alpha}')^{-1} \sum_{\alpha} U_{\alpha} W_{\alpha}$ tiene una distribución χ^2 con $n-q$ grados de libertad. cuya densidad es

$$\frac{1}{2^{\frac{1}{2}(n-q)} \Gamma\left(\frac{1}{2}(n-q)\right)} \cdot t^{\frac{1}{2}(n-q)-1} e^{-\frac{t}{2}}$$

Tenemos posteriormente que $\sum_{\alpha} U_{\alpha} W_{\alpha}$ es normal; si $P=0$, entonces $E(\sum_{\alpha} U_{\alpha} W_{\alpha})=0$, la matriz de covarianzas es

$$E\left(\sum_{\alpha} U_{\alpha} W_{\alpha} \cdot \sum_{\beta} W_{\beta} W_{\beta}'\right) = \sum_{\alpha, \beta} W_{\alpha} W_{\beta}' \delta_{\alpha, \beta} = \sum_{\alpha} W_{\alpha} W_{\alpha}'.$$

Sea $A_{(i)} = (a_{i1, i+1}, a_{i1, i+2}, \dots, a_{i1, p})$ y $A_{ii} = (a_{jk}), j, k = i+1, \dots, p$.

Entonces

$$A_{ii} = \begin{pmatrix} a_{ii} & a_{i(i)} \\ a_{i(i)} & A_{i(i+1, i+1)} \end{pmatrix}.$$

Sea $a_{ii, i+1, \dots, p} = a_{ii} - a_{(i)} A_{i(i+1, i+1)}^{-1} a_{(i)}$. El conjunto (z_{i1}, \dots, z_{in}) se distribuye independientemente de (z_{j1}, \dots, z_{jn}) , $j \neq i$ (a causa de $I=I$), y por tanto, condicionando a $z_{jk} = z_{jk}$ ($j \neq i, \alpha = 1, \dots, n$). Los elementos de (z_{i1}, \dots, z_{in}) se distribuyen independientemente, cada uno $N(0, 1)$, que es de la forma $N(PW_{\alpha}, \phi)$ con $P=0$ y $\phi=1$. Sea $Z_{\alpha}^{(i)} = (z_{j1}, z_{j+1, i}, \dots, z_{ji})$. Entonces $a_{(i)} = \sum_{\alpha} z_{\alpha} Z_{\alpha}^{(i)}$. Aplicando el caso especial del teorema citado encontramos que condicionado a $Z_{\alpha}^{(i)} = Z_{\alpha}^{(i)}$, $a_{ii, i+1, \dots, p}$ tiene una distribución χ^2 en $n-(p-i)$ grados de libertad e independiente de a_{ii} que se distribuye condicionalmente como $N(0, A_{i(i+1, i+1)})$. Se observará que la distribución condicional depende de $Z_{\alpha}^{(i)}$ sólo a través de $A_{i(i+1, i+1)}$; a definir la densidad de $a_{ii, i+1, \dots, p}$,

$a_{(1)}, a_{22, 3 \dots p}, a_{(2)}, \dots, a_{p-1, p-1, p}, a_{(p-1)}, a_{pp}$

$$f_1(a_{ii, i+1, \dots, p}) a_{ii}/A_{ii} \cdots f_{p-1}(a_{p-1, p-1, p}) a_{(p-1)}/A_{pp} \cdot f(A_{pp}) =$$

$$= \frac{a_{ii}^{\frac{1}{2}(n-p)} \cdot a_{pp}^{\frac{1}{2}}}{2^{\frac{1}{2}np} \Gamma\left(\frac{1}{2}n\right)} \cdot \prod_{i=1}^{p-1} \left\{ \frac{a_{ii, i+1, \dots, p}^{\frac{1}{2}(n-p-i)-1} \cdot a_{i(i+1, i+1)}^{\frac{1}{2}}}{2^{\frac{1}{2}(n-p-i)} \Gamma\left(\frac{1}{2}n-p\right)} \cdot \frac{a_{ii}^{\frac{1}{2}a_{ii} A_{i(i+1, i+1)}^{-1} a_{(i)}}}{(2\pi)^{\frac{1}{2}(p-i)} |A_{i(i+1, i+1)}|^{\frac{1}{2}}} \right\}$$

Encontramos la densidad de $a_{ii}, a_{(1)}, \dots, a_{pp}$ constituyendo en la expresión anterior $a_{ii, i+1, \dots, p} = a_{ii} - a_{(i)} A_{ii, i+1}^{-1} a_{ii}'$, y multiplicando por el Jacobiano, que es 1, y multiplicando posteriormente la expresión. El exponente de ϵ en la anterior igualdad es

$$\begin{aligned} -\frac{1}{2} \left[app + \sum_{i=1}^{p-1} a_{ii, i+1, \dots, p} + \sum_{i=1}^{p-1} a_{(i)} A_{ii, i+1}^{-1} a_{ii}' \right] &= -\frac{1}{2} \left[app + \sum_{i=1}^{p-1} (a_{ii} - a_{(i)} A_{ii, i+1}^{-1} a_{ii}') + \sum_{i=1}^{p-1} a_{(i)} A_{ii, i+1}^{-1} a_{ii}' \right] = \\ &= -\frac{1}{2} \sum_{i=1}^p a_{ii} = -\frac{1}{2} \text{tr} A. \end{aligned}$$

Utilizando una propiedad de los matrices, que asegura que

$$a_{ii, i+1, \dots, p} = \frac{\begin{vmatrix} a_{ii} & a_{ii} \\ a_{(i)} & A_{ii, i+1} \end{vmatrix}}{\begin{vmatrix} A_{ii, i+1} \end{vmatrix}} = \frac{|A_{ii}|}{|A_{ii, i+1}|}$$

encontramos que $(app = A_{pp})$

$$app \prod_{i=1}^{p-1} a_{ii, i+1, \dots, p} = app \prod_{i=1}^{p-1} \frac{|A_{ii}|}{|A_{ii, i+1}|} = |A_{11}| = |A|.$$

Entonces

$$app \prod_{i=1}^{p-1} \frac{a_{ii, i+1, \dots, p}}{|A_{ii, i+1}|^{\frac{1}{2}}} = |A|^{\frac{1}{2}(n-p-1)} \cdot app \prod_{i=1}^{p-1} \frac{|A_{ii}|^{\frac{1}{2}(i-1)}}{|A_{ii, i+1}|^{\frac{1}{2}}} = |A|^{\frac{1}{2}(n-p-1)}.$$

La potencia de \prod en el denominador es $\prod_{i=1}^{p-1} [\frac{1}{2}((p-i)+(p-2)+\dots+1)] = \frac{1}{2} [p(p-1)/2]$. Puesto que $\prod_{i=1}^{p-1} [\frac{1}{2}(n-(p-i))] = \prod_{i=1}^p [\frac{1}{2}(n-i+1)]$, encontramos que la densidad de $a_{ii}, a_{(1)}, \dots, a_{pp}$ es

$$\frac{|A|^{\frac{1}{2}(n-p-1)} e^{-\frac{1}{2}\text{tr} A}}{2^{\frac{1}{2}np} \pi^{p(p-1)/4} \prod_{i=1}^p \prod_{j=1}^{\frac{1}{2}(n-i+1)}}.$$

que es la expresión de (1) cuando $\Sigma = I$.

Obtenemos la distribución para Σ arbitraria. Sea $A = \sum_{x_1}^n Z_k Z_k'$, donde las Z_k son n independientes, cada una con distribución $N(0, I)$, con $A^* = \sum_{x_1}^n Z_k^* Z_k^{*T}$, donde las Z_k^* son independientes, cada una con distribución $N(0, I)$. Dado la densidad de A^* es la deseada. Sea C una matriz triangular arbitraria ($c_{ij}=0, i > j$) tal que $C^T C = I$ (siempre existe C por una propiedad de las matrices definidas positivas). La distribución de $C A C^T = \sum_{x_1}^n (C Z_k)(C Z_k)^T$ es la misma que la de A^* puesto que la distribución de $C Z_k$ es la de Z_k^* . Por tanto obtenemos la distribución de A sustituyendo $A^* = C A C^T$ en la densidad deseada y multiplicando por el Jacobiano.

LEMMA. — Sea A^* una matriz simétrica que transformamos en otra matriz simétrica A mediante $A^* = G A G^T$, donde G es una matriz triangular no singular. El Jacobiano de la transformación es $\text{mod } |G|^{p+1}$ (mod. indica módulo).

Demostración. — La transformación es

$$a_{ij}^* = \sum_{k \in E} c_{ik} a_{ik} g_{jk}.$$

Las derivadas parciales son

$$\frac{\partial a_{ij}^*}{\partial a_{ke}} = c_{ik} g_{jk}$$

$$\frac{\partial a_{ij}^*}{\partial g_{lk}} = c_{ik} g_{jl} + c_{il} g_{jk} \quad l \neq k$$

Entendemos la matriz de las derivadas parciales en el orden $a_{11}, a_{21}, \dots, a_{p1}, a_{12}, \dots, a_{p2}, \dots, a_{1p}, a_{2p}, \dots, a_{pp}$; la posición de la fila corresponde a a_{ij}^* y la posición de la columna a a_{ij} . La matriz es

$$\begin{bmatrix} C_{11}^2 & 2C_{11}C_{12} \dots 2C_{11}C_{1p} & C_{12}^2 \dots & C_{1p}^2 \\ 0 & C_{11}C_{22} \dots C_{11}C_{2p} & C_{12}C_{22} \dots C_{1p}C_{2p} & \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 \dots C_{11}C_{pp} & C_{1p}C_{pp} \dots C_{1p}C_{pp} & \\ 0 & 0 \dots 0 & C_{22}^2 \dots & C_{2p}^2 \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 \dots 0 & 0 \dots & C_{pp}^2 \end{bmatrix}$$

que es una matriz triangular. El determinante es el producto de los elementos de la diagonal, que vale $\prod_{j=1}^p C_{jj}^{p+1} = |C|^{p+1}$. lo que demuestra el lema.

Si en la densidad de A^* reemplazamos A por CAC' , de $C\Sigma C' = I$ tenemos $|I| = |\Sigma C'| = |C| \cdot |\Sigma| \cdot |C'| = |\Sigma| \cdot |CC'|$; así $|CC'| = 1/|\Sigma|$ y $|\text{rango}(C)| = 1/\sqrt{|\Sigma|}$. Además $\Sigma = C^{-1}(C')^{-1} = (C'C)^{-1}$. Así $\text{tr } CAC' = \text{tr } AC'C = \text{tr } A\Sigma^{-1}$, $|\text{rango}(CAC')| = |\text{rango}(C) \cdot |\text{rango}(A) \cdot |\text{rango}(C')| = |\text{rango}(A) \cdot |\text{rango}(C)| = |\text{rango}(A)/\sqrt{|\Sigma|}|$. Estas sustituciones y el desarrollo antisimétrico dan por resultado la expresión (1) con que hemos terminado el párrafo.

TEOREMA. - Supongamos los vectores p -dimensionales Z_1, \dots, Z_n ($n \geq p$) i.i.d. independientes, cada uno distribuido $N(0, \Sigma)$. Entonces la densidad de $A = \sum_{\alpha=1}^n Z_\alpha Z_\alpha'$ es

$$\frac{|A|^{\frac{1}{2}(n-p-1)} \cdot C^{-\frac{1}{2} \text{tr } A \Sigma^{-1}}}{2^{\frac{1}{2}np} \prod_{i=1}^p \frac{1}{2}(p-i)/4 \cdot |\Sigma|^{\frac{1}{2}n} \prod_{i=1}^p \prod_{j=1}^i (n+1-j)}$$

para A definida positiva, y 0 en el resto.

COROLARIO. - Supongamos los vectores p -dimensionales $\bar{Z}_1, \dots, \bar{Z}_N$ ($N \geq p$) i.i.d. independientes, con distribución $N(\mu, \Sigma)$. Entonces la densidad de $A = \sum_{\alpha=1}^N (\bar{Z}_\alpha - \bar{\mu})(\bar{Z}_\alpha - \bar{\mu})'$ es la anterior con $n = N - 1$.

Es costumbre denotar la densidad mediante $W(A/\Sigma, n)$ y la correspondiente distribución como $W(A/\Sigma, n)$ o bien $W(I, n)$. La primera extensión de esta distribución (Wishart, 1928) fue mediante un argumento geométrico, que estaba muy relacionado con la demostración que llevan presentando aquí. Sean $V_i = (Z_{i1}, \dots, Z_{in})$ un vector en el espacio R^n . Los elementos diagonales de A son los cuadrados de las longitudes de los vectores, $a_{ii} = V_i' V_i$, y los elementos de fuera de la diagonal están relacionados con los longitudes y los ángulos entre los vectores puesto que $a_{ij} = a_{ii} - a_{jj} - 2V_i' V_j$ es el seno del ángulo entre V_i y V_j . La matriz A admite las longitudes y configuración de los vectores.

El elemento de probabilidad de $\sqrt{a_{ii}}/V_i, \sqrt{a_{ii}}/V_{i1}, \dots, \sqrt{a_{ii}}/V_{ip}$ dados V_{i1}, \dots, V_{ip} es aproximadamente la probabilidad de que V_i caiga en la región para la que $\sqrt{a_{ii}} < \sqrt{a_{ii}}/V_p < a_{ii} + da_{ii}$. El primer parámetro define la región entre dos hipéplanes. En esta región la densidad $(2\pi)^{\frac{1}{2}n} a_{ii}^{(p-1)/2} e^{-a_{ii}/2} \sqrt{a_{ii}}/V_i$ es aproximadamente constante. La intersección de las regiones es un cosquete sferico en $n-(p-1)$ dimensiones, con una razón transversal de $p-1$ dimensiones. El volumen de esta sección es aproximadamente $d\sqrt{a_{ii}}/da_{ii} \dots da_{ip}/|A_{(i),1\dots p}|^{1/2}$. El radio es el radio del cosquete sferico $\sqrt{a_{ii} - a_{ii}a_{ii}/A_{(i),1\dots p}} = \sqrt{a_{ii}} \sqrt{1 - a_{ii}/A_{(i),1\dots p}}$. El área (o volumen) de esta superficie es la potencia $[n-(p-1)-1]$. Existe el radio por el área de la sección de la esfera (en $n-(p-1)$ dimensiones) de radio unidad. El área de la sección de la esfera unitaria es $G(n-(p-1)) = 2\pi^{\frac{1}{2}[n-(p-1)]}/\prod_{i=1}^{\frac{1}{2}[n-(p-1)]} i$. Así la probabilidad de $\sqrt{a_{ii}}/V_i, \sqrt{a_{ii}}/V_{i1}, \dots, \sqrt{a_{ii}}/V_{ip}$ es

$$\frac{\int_{\frac{1}{2}[n-(p-1)]}^{\frac{1}{2}\sqrt{a_{ii}}} \frac{2\pi^{\frac{1}{2}[n-(p-1)]}}{\prod_{i=1}^{\frac{1}{2}[n-(p-1)]} i} \cdot \frac{d\sqrt{a_{ii}}/da_{ii}}{|A_{(i),1\dots p}|^{1/2}}}{(2\pi)^{\frac{1}{2}n}}$$

El elemento de probabilidad de $\sqrt{a_{ii}}/V_i, \sqrt{a_{ii}}/V_{i1}, \dots, \sqrt{a_{ii}}/V_{ip}$ impone la condición de $d\sqrt{a_{ii}}/da_{ii} = da_{ii}/(2\sqrt{a_{ii}})$. Esto incluye al i -ésimo término del producto antisimétrico y que representaba la densidad de $a_{11}, a_{12}, \dots, a_{1p}, a_{21}, a_{22}, \dots, a_{2p}, a_{31}, \dots, a_{3p}, \dots, a_{(p-1)1}, a_{(p-1)p}, a_{pp}$.

Existen otros muchos métodos para llegar a este resultado (vea Anderson pag. 158).

Para terminar este párrafo daremos la distribución conjunta de los varianzas y covarianzas muestrales. Hemos demostrado que N_{Σ}^2 , para muestras de tamaño N que provienen de una $N(\mu, \Sigma)$ se distribuye como $\sum_{\alpha=1}^n Z_\alpha Z_\alpha'$ donde los Z_α son independientes, cada uno con

distribución $N(0, \Sigma)$ y $n = N - 1$, $E(N\Sigma) = n\Sigma$, y $E(S) = \Sigma$, donde $S = (N/n)\hat{\Sigma}$.

TEOREMA. - Supongamos que Z_1, \dots, Z_N ($N \geq p+1$) se distribuyen independientemente, cada una como $N(\mu, \Sigma)$. Entonces la distribución de $S = (\frac{1}{n}) \sum_{\alpha=1}^n (Z_{\alpha} - \bar{Z})(Z_{\alpha} - \bar{Z})'$ es $W[(\frac{1}{n})\Sigma, n]$, donde $n = N - 1$ y $W[(\frac{1}{n})\Sigma, n]$ es la distribución de Wishart con matriz de covarianzas $(\frac{1}{n})\Sigma$ y n grados de libertad.

Demostración.- Claramente, $S = (\frac{1}{n})A = \sum_{\alpha=1}^n [(\frac{1}{n}Z_{\alpha})] [(\frac{1}{n}Z_{\alpha})']$, donde los $(\frac{1}{n}Z_{\alpha})$ son independientes, con distribución $N(0, (\frac{1}{n})\Sigma)$. Otros basta aplicar el teorema anterior a los mismos $Z_{\alpha}' = (\frac{1}{n}Z_{\alpha})$.

Si $n < p$, la matriz $A = \sum_{\alpha=1}^n Z_{\alpha}Z_{\alpha}'$ no tiene una densidad de probabilidad. No obstante, nos referiremos a la distribución correspondiente, como a la distribución de Wishart.

3. ALGUNAS PROPIEDADES DE LA DISTRIBUCIÓN DE WISHART

La Función Característica

La función característica de la distribución de Wishart puede obtenerse fácilmente a partir de la distribución de las observaciones. Supongamos que Z_1, \dots, Z_n se distribuyen independientemente, cada una en densidad

$$\frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{n}{2}}} \exp(-\frac{1}{2} z' \Sigma^{-1} z).$$

Sea

$$A = \sum_{\alpha=1}^n Z_{\alpha}Z_{\alpha}'.$$

Introducimos la matriz $\Theta = (\theta_{ij})$ con $\theta_{ij} = \theta_{ji}$. La función característica de $A_1, A_2, \dots, A_p, 2A_1, 2A_2, \dots, 2A_{p-1}, p$ es

$$E[\exp(i \operatorname{tr}(A\Theta))] = E[\exp(i \operatorname{tr} \sum_{\alpha=1}^n Z_{\alpha}Z_{\alpha}' \Theta)] = E[\exp(i \operatorname{tr} \sum_{\alpha=1}^n Z_{\alpha}' \Theta Z_{\alpha})] = E[\exp(i \sum_{\alpha=1}^n Z_{\alpha}' \Theta Z_{\alpha})]$$

en virtud del hecho de que $\operatorname{tr} EFG = \sum_{j=1}^p f_{jj} g_{jj} = \operatorname{tr} FGE$. Como las Z_{α} son independientes, tendremos

$$E[\exp(i \sum_{\alpha=1}^n Z_{\alpha}' \Theta Z_{\alpha})] = \prod_{\alpha=1}^n E[\exp(i Z_{\alpha}' \Theta Z_{\alpha})] = \left\{ E[\exp(i Z_{\alpha}' \Theta Z_{\alpha})] \right\}^n.$$

Para Θ real existe una matriz B , real no singular tal que

$$B'\Sigma^{-1}B = I$$

$$B'\Theta B = D$$

donde D es una matriz diagonal. Si hacemos

$$z = By$$

entonces

$$E[\exp(i z' \Theta z)] = E[\exp(i y' D y)] = E\left[\prod_{j=1}^p \exp(i d_{jj} y_j^2)\right] = \prod_{j=1}^p E[\exp(i d_{jj} y_j^2)].$$

El j -ésimo término en el producto es la $E[\exp(i d_{jj} y_j^2)]$ donde y_j tiene una distribución $N(0, 1)$; y pues la función característica de la distribución χ^2 con un grado de libertad, es decir $(1 - 2i d_{jj})^{-\frac{1}{2}}$. Así

$$E[\exp(i z' \Theta z)] = \prod_{j=1}^p (1 - 2i d_{jj})^{-\frac{1}{2}} = |I - 2iD|^{-\frac{1}{2}}$$

puesto que $I - 2iD$ es una matriz diagonal. Recuerda en cuenta lo que vale D y lo que vale I , tendremos

$$|I - 2iD| = |B'\Sigma^{-1}B - 2iB'\Theta B| = |B'(I - 2i\Theta)B| = |B'| \cdot |\Sigma^{-1} - 2i\Theta| \cdot |B| = |B|^2 \cdot |\Sigma^{-1} - 2i\Theta|$$

$|B'| \cdot |\Sigma^{-1}| \cdot |B| = |I| = 1$, y $|B|^2 = 1/|\Sigma^{-1}|$. Combinando estos resultados, establecemos

$$E[\exp(i \operatorname{tr}(A\Theta))] = \frac{|\Sigma^{-1}|^{\frac{1}{2}n}}{|\Sigma^{-1} - 2i\Theta|^{\frac{1}{2}n}}.$$

Puede demostrarse que este resultado es válido contabil que $\text{re}(\theta^{jk} - 2i\theta_{jk})$ sea definita positiva. De particular es cierto para todo θ real.

TEOREMA. - Si Z_1, \dots, Z_n son independientes, cada una con distribución $N(0, \Sigma)$, la función característica de $A_{11}, \dots, A_{1n}, 2A_{12}, \dots, 2A_{1p}$,

$$\text{donde } (A_{ij}) = A = \sum_{\alpha=1}^n Z_\alpha Z_\alpha^T,$$

$$f(\theta) = \frac{|\Sigma^{-1}|^{1/2}}{|\Sigma^{-1} - 2i\theta|^{1/2}}$$

Podemos obtener los momentos de A , bien a partir de la función característica, bien a partir de la distribución marginal. El valor esperado de A_{ij} es

$$E(A_{ij}) = E\left[\sum_{\alpha=1}^n Z_{i\alpha} Z_{j\alpha}\right] = \sum_{\alpha=1}^n \sigma_{ij} = n\sigma_{ij}.$$

Para obtener las covariancias necesitamos

$$\begin{aligned} E(A_{ij} A_{ke}) &= E\left[\sum_{\alpha, \beta=1}^n Z_{i\alpha} Z_{j\alpha} Z_{k\beta} Z_{e\beta}\right] = E\left[\sum_{\alpha=1}^n Z_{i\alpha} Z_{j\alpha} Z_{k\alpha} Z_{e\alpha}\right] + E\left[\sum_{\substack{\alpha, \beta=1 \\ \alpha \neq \beta}}^n Z_{i\alpha} Z_{j\alpha} Z_{k\beta} Z_{e\beta}\right] = \\ &= n(\sigma_{ij}\sigma_{ke} + \sigma_{ik}\sigma_{je} + \sigma_{ie}\sigma_{jk}) + n(n-1)\sigma_{ij}\sigma_{ke} = n^2\sigma_{ij}\sigma_{ke} + n\sigma_{ik}\sigma_{je} + n\sigma_{ie}\sigma_{jk}, \end{aligned}$$

siendo los momentos de menor orden los definidos en un momento cuando estudiáramos la normal multivariante. Así, la covarianza entre A_{ij} , A_{ke} es

$$E[(A_{ij} - n\sigma_{ij})(A_{ke} - n\sigma_{ke})] = n\sigma_{ik}\sigma_{je} + n\sigma_{ie}\sigma_{jk}.$$

Para $i=k$ y $j=l$ obtendremos la variancia de A_{ij}

$$E[(A_{ij} - n\sigma_{ij})^2] = n(\sigma_{ij}^2 + \sigma_{ii}\sigma_{jj}).$$

La suma de matrices de Wishart

Supongamos que A_i ($i=1, 2$) se distribuyen independientemente como $W(\Sigma, n_i)$ respectivamente. Entonces A_1 se distribuye como $\sum_{\alpha=1}^{n_1} Z_\alpha Z_\alpha^T$ y A_2 como $\sum_{\alpha=n_1+1}^{n_1+n_2} Z_\alpha Z_\alpha^T$, donde las Z_α son independientes, cada una $N(0, \Sigma)$. Entonces

$$A = A_1 + A_2$$

se distribuye como $\sum_{\alpha=1}^n Z_\alpha Z_\alpha^T$ con $n = n_1 + n_2$. Es decir, A se distribuye $W(\Sigma, n)$. Obviamente la suma de q matrices, distribuidas independientemente, cada una con distribución Wishart de covarianza Σ , tiene una distribución Wishart en matriz Σ y número de grados de libertad igual a la suma de los grados de libertad de las matrices componentes.

Una cierta transformación lineal

Planteemos físicamente la transformación

$$A = CBC'$$

donde C es una matriz no singular $p \times p$. Si A se distribuye como $W(\Sigma, n)$, entonces B se distribuye como $W(\Phi, n)$ donde

$$\Phi = C^{-1} \Sigma C^{-1}.$$

Esto se prueba mediante el siguiente argumento:

$$A = \sum_{\alpha=1}^n Z_\alpha Z_\alpha^T,$$

donde Z_α se distribuyen independientemente, cada una como $N(0, \Sigma)$. Entonces

$$Y_\alpha = C^{-1} Z_\alpha$$

se distribuye como $N(0, \Phi)$. Por tanto,

$$B = \sum_{\alpha=1}^n Y_\alpha Y_\alpha' = C^{-1} \sum_{\alpha=1}^n Z_\alpha Z_\alpha' C^{-1} = C^{-1} A C^{-1}$$

se distribuye como $W(\phi, n)$. El Jacobiano de la transformación, $\left| \frac{\partial(A)}{\partial(B)} \right|$, viene dado por

$$\left| \frac{\partial(A)}{\partial(B)} \right| = \frac{w(B, \phi, n)}{w(A, I, n)} = \frac{|B|^{\frac{1}{2}(n-p+1)} |\Sigma|^{\frac{1}{2}n}}{|A|^{\frac{1}{2}(n-p+1)} |\phi|^{\frac{1}{2}n}} = \text{mod } |C|^{p+1}.$$

Distribuciones marginales

Si A se distribuye $W(\Sigma, n)$, la distribución marginal de algunos subconjuntos de elementos de A puede ser difícil de obtener. No obstante, la distribución marginal de algunos conjuntos de elementos puede obtenerse con facilidad. Veamos algo de esto con los siguientes teoremas.

TEOREMA.- Sean A y Σ fraccionadas en q y $p-q$ filas y columnas

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$$

Si A se distribuye $W(\Sigma, n)$, entonces A_{11} lo hace $W(\Sigma_{11}, n)$.

Demonstración.- A se distribuye como $\sum_{\alpha=1}^n Z_\alpha Z_\alpha'$, donde los Z_α son independientes, cada uno con distribución $N(0, \Sigma)$. Fraccionamos Z_α en dos subvectores de q y $p-q$ componentes respectivamente,

$$Z_\alpha = \begin{pmatrix} Z_\alpha^{(1)} \\ Z_\alpha^{(2)} \end{pmatrix}.$$

Entonces $Z_\alpha^{(1)}$ son independientes, cada uno con distribución $N(0, \Sigma_{11})$, y A_{11} se distribuye como $\sum_{\alpha=1}^n Z_\alpha^{(1)} Z_\alpha^{(1)'} = \Sigma_{11}$, que tiene una distribución $W(\Sigma_{11}, n)$.

TEOREMA.- Sean A y Σ fraccionadas en p_1, \dots, p_q filas y columnas ($p_1 + p_2 + \dots + p_q = p$)

$$A = \begin{pmatrix} A_{11} & \cdots & A_{1q} \\ \vdots & \ddots & \vdots \\ A_{q1} & \cdots & A_{qq} \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \Sigma_{11} & \cdots & \Sigma_{1q} \\ \vdots & \ddots & \vdots \\ \Sigma_{q1} & \cdots & \Sigma_{qq} \end{pmatrix}$$

Si $\Sigma_{ij} = 0$ para $i \neq j$ y si A se distribuye como $W(\Sigma, n)$, entonces $A_{11}, A_{21}, \dots, A_{q1}$ son independientes y se distribuyen $W(\Sigma_{jj}, n)$.

Demonstración.- Fraccionamos Z_α de la forma

$$Z_\alpha = \begin{pmatrix} Z_\alpha^{(1)} \\ \vdots \\ Z_\alpha^{(q)} \end{pmatrix}$$

Puesto que $\Sigma_{ij} = 0$, $Z_\alpha^{(i)}$ y $Z_\alpha^{(j)}$ son independientes, $\forall i, j$. Entonces $A_{11} = \sum_{\alpha=1}^n Z_\alpha^{(1)} Z_\alpha^{(1)'} = \Sigma_{11}$ es independiente de $A_{jj} = \sum_{\alpha=1}^n Z_\alpha^{(j)} Z_\alpha^{(j)'}$. El resto del teorema se deriva del anterior.

4. EL TEOREMA DE COCHRAN

El teorema de Cochran es útil para probar que ciertas "formas cuadráticas vectoriales" se distribuyen como sumas de "cuadrados vectoriales". Es una afirmación estadística de un teorema algebraico. Daremos en primer lugar la proposición algebraica correspondiente a variables escalares.

LEMÁ.- Si

$$q_i = \sum_{\alpha, \beta=1}^N a_{\alpha\beta} Y_\alpha Y_\beta, \quad i=1, \dots, m$$

s de rango r_i y

$$\sum_{i=1}^m q_i = \sum_{\alpha=1}^N Y_\alpha^2$$

entonces una condición necesaria y suficiente para que existe una transformación ortogonal de $\{y_i\}$ a $\{z_i\}$ 6(4)

tal que

$$q_i = \sum_{\alpha=1}^{r_1+ \dots + r_i} z_\alpha^2$$

$$\alpha = r_1 + \dots + r_{i-1} + 1$$

o que

$$r_1 + \dots + r_m = N$$

Demonstración. - La necesidad de la condición es obvia porque la suma de los rangos no puede ser menor que N si se verifica que

$$\sum_{i=1}^m q_i = \sum_{\alpha=1}^N y_\alpha^2$$

y no puede ser mayor que N ni la transformación que pasa a $z_1, \dots, z_{r_1+r_2+\dots+r_m}$ ha de ser no singular.

Probarámos pues la suficiencia. De una propiedad matricial sabemos que existe una matriz no singular D , tal que

$$D' \begin{pmatrix} I & 0 & 0 \\ 0 & -I & 0 \\ 0 & 0 & 0 \end{pmatrix} D = A_2$$

donde $A_2 = (\alpha_{ij})$ y la suma de los ordenes de I y $-I$ es r_2 . Sea $c_{\alpha\beta} = b_{\alpha\beta}^{(1)}$, $\alpha = 1, \dots, r_1$, $\beta = 1, \dots, N$. Entonces

$z_\alpha = \sum_{\beta=1}^N b_{\alpha\beta}^{(1)} y_\beta$ ($\alpha = 1, \dots, r_1$) forman un conjunto de r_1 funciones lineales de $\{y_\beta\}$ tal que

$$q_i = \sum_{\alpha=1}^{r_i} c_{\alpha} z_\alpha^2$$

donde $c_\alpha = 1 \text{ o } -1$. En general existe un conjunto de r_i funciones lineales

$$z_\alpha = \sum_{\beta=1}^N b_{\alpha\beta}^{(1)} y_\beta \quad , \quad \alpha = r_1 + \dots + r_{i-1} + 1, \dots, r_1 + \dots + r_i$$

tal que

$$q_i = \sum_{\alpha=r_1+\dots+r_{i-1}+1}^{r_1+\dots+r_i} c_\alpha z_\alpha^2$$

Así

$$\sum_{i=1}^m q_i = \sum_{\alpha=1}^N c_\alpha z_\alpha^2$$

pero como la $\sum q_i$ es definida positiva los c_α han de ser todos positivos, $c_\alpha = 1, \forall \alpha$. Por tanto se verifica la igualdad

$$q_i = \sum_{\alpha=r_1+\dots+r_{i-1}+1}^{r_1+\dots+r_i} z_\alpha^2$$

Además sumando los z_α para todos los i , tendremos

$$z_\alpha = \sum_{\beta=1}^N b_{\alpha\beta} y_\beta \quad , \quad \alpha = 1, \dots, N$$

pero

$$\sum_{i=1}^m q_i = \sum_{\alpha=1}^N z_\alpha^2 = \sum_{\alpha=1}^N y_\alpha^2$$

lo que impone que la transformación que pasa de las $\{y_i\}$ a las $\{z_i\}$ es ortogonal (a saber, $I = B'IB = B'B$).

Una expresión alternativa del lema es la siguiente: Sea R_i el rango de la matriz de orden N , A_i , matriz que satisface además simetría ($i = 1, \dots, m$), y supongamos $\sum_{i=1}^m A_i = I$. Una condición necesaria y suficiente para que existe una matriz ortogonal

$$B = \begin{pmatrix} B_1 \\ \vdots \\ B_m \end{pmatrix}$$

Tal que $A_i = B_i^T B_i \Rightarrow$ que $\sum_{i=1}^m r_i = N$.

Estableceremos a continuación el teorema de Cochran.

TEOREMA DE COCHRAN. - Supongamos que Y_α se distribuye $N(\bar{Y}, \Sigma)$, independientemente de Y_β ($\alpha \neq \beta$). Supongamos que la matriz $A_i = (a_{\alpha\beta}^i)$ utilizada para probar

$$Q_i = \sum_{\alpha, \beta=1}^N a_{\alpha\beta} Y_\alpha Y_\beta^T \quad i = 1, \dots, m$$

es de rango r_i y supongamos

$$\sum_{i=1}^m Q_i = \sum_{\alpha=1}^N Y_\alpha Y_\alpha^T.$$

Entonces una condición necesaria y suficiente para que Q_i ($i = 1, \dots, m$) se distribuya como

$$\begin{cases} r_1 + \dots + r_m \\ Z_\alpha Z_\alpha^T \\ r_1 + \dots + r_m + 1 \end{cases}$$

donde las Z_α son $N(0, \Sigma)$ e independientes y Q_i se distribuya independientemente de Q_j ($i \neq j$) y que

$$r_1 + \dots + r_m = N.$$

COROLARIO. - Si $r_i \geq p$, entonces Q_i se distribuye como $W(\Sigma, r_i)$

Demostración. - Si $r_1 + r_2 + \dots + r_m = N$ se verifica, existe una matriz ortogonal B tal que $A_i = B_i^T B_i$. Puesto que B es ortogonal

$$Z_\alpha = \sum_{\beta=1}^N b_{\alpha\beta} Y_\beta$$

son independientes, cada uno con distribución $N(0, \Sigma)$, por una propiedad ya estudiada de este tipo de transformaciones.

Tenemos que

$$Q_i = \sum_{\alpha, \beta=1}^N a_{\alpha\beta} Y_\alpha Y_\beta^T = \sum_{\alpha, \beta} b_{\alpha\beta} b_{\beta\alpha} Y_\alpha Y_\beta^T = \sum_{\gamma=1}^{r_i + r_m} Z_\gamma Z_\gamma^T.$$

La necesidad se demuestra mediante una argumentación análoga a la del lema anterior.

Este teorema es útil para generalizar resultados de análisis de la varianza multivariante, de ellos nos ocuparemos más tarde. Como un ejemplo de aplicación del teorema, probaremos que ~~es~~ una muestra de tamaño N ~~proporciona~~ la media de ~~esta~~ las matrices resultantes al multiplicar una observación por su traspuesta, que es exactamente N veces el vector media muestral por su traspuesta y un múltiplo de la matriz de covarianzas muestral se distribuyen independientemente con distribución Wishart singular y no singular respectivamente. Sea Y_1, \dots, Y_N vectores aleatorios independientes $N(0, \Sigma)$. Utilizaremos las matrices $(a_{\alpha\beta}^{(1)}) = (1/N)$ y $(a_{\alpha\beta}^{(2)}) = [\delta_{\alpha\beta} - (1/N)]$

Entonces

$$Q_1 = \sum_{\alpha, \beta=1}^N \frac{1}{N} Y_\alpha Y_\beta^T = N \bar{Y} \bar{Y}^T$$

$$Q_2 = \sum_{\alpha, \beta=1}^N (\delta_{\alpha\beta} - \frac{1}{N}) Y_\alpha Y_\beta^T = \sum_{\alpha=1}^N Y_\alpha Y_\alpha^T - N (\bar{Y} \bar{Y}^T) = \sum_{\alpha=1}^N (Y_\alpha - \bar{Y})(Y_\alpha - \bar{Y})^T.$$

Obligatoriamente

$$Q_1 + Q_2 = \sum_{\alpha=1}^N Y_\alpha Y_\alpha^T.$$

La primera matriz es de rango 1; la segunda matriz es de rango $(N-1)$ (puesto que el rango de la suma de dos matrices es menor o igual que el menor de los rangos y el rango de la segunda matriz es menor que N). Las condiciones del teorema se cumplen; por tanto, Q_1

se distribuye como ZZ' , donde $Z \sim N(0, \Sigma)$ y Z se distribuye independientemente como $W(\Sigma, N-1)$.

65

5. LA VARIANZA GENERALIZADA

El concepto multivariante equivalente a la varianza, S^2 , de una distribución univariante es la matriz de covarianzas Σ . Otro concepto multivariante análogo es el escalar $|S|$, que se le llama varianza generalizada de la distribución multivariante. Analogamente, la varianza generalizada de la muestra de vectores x_1, \dots, x_N es

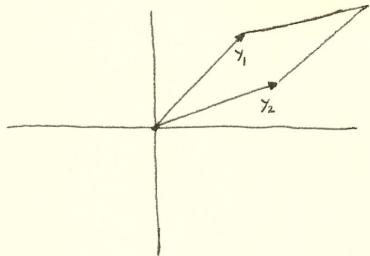
$$|S| = \left| \frac{1}{N-1} \sum_{\alpha=1}^N (x_\alpha - \bar{x})(x_\alpha - \bar{x})' \right|.$$

En algún sentido es una medida de extensión. Consideramos aquí este concepto porque se reduce a él en muchos contrastes de hipótesis basados en la razón de verosimilitud.

Una interpretación geométrica de la varianza multivariante generalizada puede darse en términos de p puntos en el espacio N -dimensional. Sea $Z_\alpha = x_\alpha - \bar{x}$, y hagamos

$$\begin{pmatrix} y_1 \\ \vdots \\ y_p \end{pmatrix} = (z_1, \dots, z_N).$$

Los N componentes del vector y_i son los i -índices componentes de z_1, \dots, z_N . Entonces $|y_i| = y_1 y_i$ es el cuadrado de la longitud del i -índice vector y_i y $C_{ij} = y_i y_j$ es el producto del seno del ángulo entre y_i y y_j por la longitud de y_i y y_j . Consideremos ahora



la figura basada en dos de estos vectores. Si $p=2$, tenemos un paralelogramo con y_1 y y_2 como ejes principales; si $p=3$, tenemos un paralelepípedo con y_1, y_2 y y_3 como ejes principales. Para p cualquiera, la figura es un paralelepípedo en el hiperplano p -dimensional definido mediante y_1, \dots, y_p . Esté delimitado por planos de hiperplanos ($p-1$)-dimensionales, un hiperplano del par situado definido mediante $p-1$ vectores y el otro pasando por el extremo del vector que falta. El determinante $|A| = |(N-1)S| = (N-1)^p |S|$ es el cuadrado del volumen de este paralelepípedo.

TEOREMA. — Sea $y = (y_1, \dots, y_p)$, donde los y_i son vectores N -dimensionales. Entonces el cuadrado del volumen p -dimensional del paralelepípedo con y_1, \dots, y_p como ejes principales es $|y'y| = |A| = (N-1)^p |S|$.

Demostración. — El teorema es cierto si $p=1$, puesto que $|y'y| = y_1^2 y_1$, cuadrado de la longitud de y_1 . Supongamos cierto para $p=k-1$ y probaremos para $p=k$. Señalemos primero que si los paraleleptopos k -dimensionales tienen bases consistentes en paraleleptopos $(k-1)$ -dimensionales de igual volumen e igual altura, sus volúmenes (k -dimensionales) serán iguales (por cuanto dicho volumen es la integral del volumen $(k-1)$ -dimensional). Puesto que es cierto para un paralelepípedo rectangular, el volumen k -dimensional es el producto de la altura por el volumen $(k-1)$ -dimensional de la base. Una combinación lineal de y_1, \dots, y_{k-1} , por ejemplo, $c_1 y_1 + \dots + c_{k-1} y_{k-1}$ es un vector en la base del paralelepípedo y la mínima longitud de $v = y_k - (c_1 y_1 + \dots + c_{k-1} y_{k-1})$ es la altura del paralelepípedo con y_1, \dots, y_k como ejes principales. La longitud de v se minimiza elegiendo c_1, \dots, c_{k-1} de manera que

$$0 = y_j^j v = y_j^j y_k - (c_1 y_1^j + \dots + c_{k-1} y_{k-1}^j y_{k-1}). \quad j=1, \dots, k-1. \quad \text{Sea } Y_k = (y_1, \dots, y_k) \text{ e } Y_{k-1} = (y_1, \dots, y_{k-1}),$$

$$G = \begin{pmatrix} 1 & 0 & \dots & 0 & -c_1 \\ 0 & 1 & \dots & 0 & -c_2 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & 1 & -c_{k-1} \\ 0 & 0 & \dots & 0 & 1 \end{pmatrix}$$

Entonces $|G|=1$ y $(Y_{k-1}, v) = Y_k G$. Tenemos

$$|y_k^j y_k| = |G| \cdot |Y_k^j Y_k| \cdot |G| = |G^j Y_k^j Y_k G| = \left| \begin{pmatrix} y_{k-1}^j \\ v^j \end{pmatrix} (Y_{k-1}, v) \right| = \begin{vmatrix} y_{k-1}^j y_{k-1} & 0 \\ 0 & v^j v \end{vmatrix} = |y_{k-1}^j y_{k-1}| v^j v.$$

Puesto que hemos supuesto que $|y_{k-1}^j y_{k-1}|$ era el cuadrado del volumen $(k-1)$ -dimensional de la base del paralelepípedo, $v^j v$ es el cuadrado de la altura, el producto es el cuadrado del volumen del paralelepípedo k -dimensional. Hemos probado el teorema por inducción.

Veremos más tarde que muchos conceptos de estadística multivariante tienen una interpretación en términos de estos volúmenes. Estos volúmenes son análogos a las distancias que surgen en casos especiales cuando $p=1$.

Consideremos ahora una interpretación geométrica de $|A|$ entendiéndolo como el volumen de N puntos en un espacio p -dimensional. Sean z_1, \dots, z_N definidos como antes, representar N puntos en el espacio p -dimensional. Cuando $p=1$, $|A| = \sum_{\alpha} z_{1\alpha}^2$, que es la suma de los cuadrados de las distancias de cada punto al origen. De general, $|A|$ es la suma de los volúmenes de todos los paralelepípedos formados tomando como ejes principales vectores del conjunto z_1-z_N .

Sabemos que

$$|A| = \begin{vmatrix} \sum_{\alpha} z_{1\alpha}^2 & \dots & \sum_{\alpha} z_{1\alpha} z_{p-1\alpha} & \sum_{\beta} z_{1\beta} z_{p\beta} \\ \vdots & \ddots & \vdots & \vdots \\ \sum_{\alpha} z_{p-1\alpha} z_{1\alpha} & \dots & \sum_{\alpha} z_{p-1\alpha}^2 & \sum_{\beta} z_{p-1\beta} z_{p\beta} \\ \sum_{\alpha} z_{p\alpha} z_{1\alpha} & \dots & \sum_{\alpha} z_{p\alpha} z_{p-1\alpha} & \sum_{\beta} z_{p\beta}^2 \end{vmatrix} = \prod_{\beta} \begin{vmatrix} \sum_{\alpha} z_{1\alpha}^2 & \dots & \sum_{\alpha} z_{1\alpha} z_{p-1\alpha} & \sum_{\beta} z_{1\beta} z_{p\beta} \\ \sum_{\alpha} z_{p-1\alpha} z_{1\alpha} & \dots & \sum_{\alpha} z_{p-1\alpha}^2 & \sum_{\beta} z_{p-1\beta} z_{p\beta} \\ \sum_{\alpha} z_{p\alpha} z_{1\alpha} & \dots & \sum_{\alpha} z_{p\alpha} z_{p-1\alpha} & \sum_{\beta} z_{p\beta}^2 \end{vmatrix}$$

por la regla del desarrollo de un determinante. Aplicando este procedimiento repetidas veces a las columnas, tendremos

$$|A| = \sum_{\alpha_1, \dots, \alpha_p=1}^N |z_{1\alpha_1} z_{p\alpha_p}|.$$

Por el teorema anterior el cuadrado del volumen del paralelepípedo con ejes principales $z_{\alpha_1} - z_{\alpha_p}$ es

$$V_{\alpha_1, \dots, \alpha_p}^2 = \left| \sum_{\beta} z_{1\beta} z_{p\beta} \right|$$

donde la suma sobre β se extiende a todos los $(\alpha_1, \dots, \alpha_p)$. Si desandallamos este determinante de la misma forma que lo hicimos con $|A|$ obtenemos

$$V_{\alpha_1, \dots, \alpha_p}^2 = \left| \sum_{\beta} z_{1\beta} z_{p\beta} \right|$$

donde la suma es para cada β_j sobre el rango $(\alpha_1, \dots, \alpha_p)$. Sumando ahora sobre todos los posibles conjuntos $(\alpha_1, \dots, \alpha_p)$ obtendremos precisamente $|A|$. Así pues $|A|$ es la suma de los volúmenes de todos los paralelepípedos formados por conjuntos de p vectores de los z_α como ejes principales. Si reemplazamos z_α mediante $x_\alpha - \bar{x}$, podemos enunciar el siguiente teorema:

TEOREMA. — Sean x_1, \dots, x_N una muestra de tamaño N y sea $|\Sigma|$ el determinante de la matriz de covarianzas muestral. Entonces $|\Sigma|$ es proporcional a la suma de los cuadrados de los volúmenes de todos los paralelepípedos formados utilizando como ejes principales vectores de la forma $(x_i - \bar{x})$, elegidos los x_i entre los x_1, \dots, x_N , siendo el factor de proporcionalidad $1/(N-1)^p$.

El equivalente probabilístico de $|\Sigma| \rightarrow |\Sigma|$, del que también puede darse una interpretación. Sabemos que

$$P \{ \mathbf{x}' \Sigma^{-1} \mathbf{x} \leq \chi_p^2(\alpha) \} = 1 - \alpha$$

si \mathbf{x} se distribuye $N(0, \Sigma)$, es decir, la probabilidad de que \mathbf{x} caiga en el interior del elipsoidal $\mathbf{x}' \Sigma^{-1} \mathbf{x} = \chi_p^2(\alpha)$, es $1 - \alpha$. El volumen de este elipsoidal viene dado por $C(\rho) |\Sigma|^{\frac{1}{2}} [\chi_p^2(\alpha)]^{\frac{1}{2}p}/p$, con $C(\rho) = \frac{2\pi^{\frac{1}{2}n}}{\Gamma(\frac{1}{2}n)}$

Distribución de la varianza muestral generalizada

La distribución de $|\Sigma|$ es la misma que la de $|A|/(N-1)^p$, donde

$$A = \sum_{\alpha=1}^n z_{\alpha} z_{\alpha}'$$

y z_α se distribuye, independientemente de $z_{\beta} (\alpha \neq \beta)$, como $N(0, I)$, $n=N-1$. Hacemos

$$W_{\alpha} = C z_{\alpha}$$

donde C ha sido elegida de manera que $C C' = I$. Entonces W_{α} se distribuye, independientemente de $W_{\beta} (\alpha \neq \beta)$, como $N(0, I)$ y

$$|B| = |A| / |\Sigma|$$

donde

$$B = \sum_{\alpha=1}^n W_{\alpha} W_{\alpha}' = \sum_{\alpha=1}^n C z_{\alpha} z_{\alpha}' C' = C A C'.$$

$$\Rightarrow |C| \cdot |\Sigma| \cdot |C'| = 1.$$

Como hicimos en un apartado anterior, sea $B_{ii} = (b_{jik})$. $j, k = i, \dots, p$, $b_{(i)} = (b_{i,ii}, b_{i,i+1}, \dots, b_{i,p})$. 6(6)

$$b_{i,i+1}, \dots, p = b_{ii} - b_{(i)} B_{i,i+1}^{-1} b_{(i)}^T. \text{ Entonces}$$

$$|B| = b_{1,2,\dots,p} b_{2,3,\dots,p} \dots b_{pp}.$$

Como vimos en el apartado 2 de este capítulo, los $b_{1,2,\dots,p}, b_{2,3,\dots,p}, \dots, b_{pp}$ son independientes, y $b_{1,2,\dots,p}$ tiene una distribución χ^2 con $n-(p-i)$ grados de libertad. Así $|B|$ se distribuye como $\chi^2_{n-1} \cdot \chi^2_{n-2} \dots \chi^2_{n-p+1}$.

TEOREMA.- La distribución de la varianza generalizada $|S|$ de una muestra X_1, \dots, X_N de una $N(\mu, I)$ es la misma que la distribución de $|\Sigma|/(N-1)^p$ por el producto de p factores independientes, siendo la distribución del factor i -ésimo una χ^2 con $N-i$ grados de libertad.

Podemos dar inmediatamente una interpretación geométrica de este teorema. Sea $Y_i = (W_{i1}, \dots, W_{in})$ un vector en un espacio n -dimensional. Los puntos Y_1, \dots, Y_p se distribuyen independientemente; cada componente de Y_i se distribuye como $N(0, 1)$. $|B|$ es el cuadrado del volumen del paralelepípedo definido mediante Y_1, \dots, Y_p . Sea U_i el vector dual de Y_i ortogonal a Y_{i+1}, \dots, Y_p . Entonces el cuadrado del volumen del paralelepípedo definido mediante Y_{i+1}, \dots, Y_p, Y_i es el volumen al cuadrado del paralelepípedo definido mediante Y_{i+1}, \dots, Y_p por $U_i U_i = A_{i,i+1}, \dots, p$ (longitud al cuadrado de U_i). Se sigue que $|B| = U_1 U_1 \cdot U_2 U_2 \dots U_p U_p$. U_i es ortogonal a U_{i+1}, \dots, U_p , por tanto la distribución condicional de U_i es normal en $(n-p+i)$ dimensiones y las $n-(p-i)$ coordenadas restantes siguen $N(0, 1)$. Así $U_i U_i$ tiene una χ^2 en $n-(p-i)$ grados de libertad (independiente de las otras U_i).

Para $p=1$ o 2 , la distribución exacta de $|S|$ puede obtenerse con cierta facilidad, pero para valores de p más elevados las integrales involucradas en el proceso no son sencillas. No obstante, los momentos de $|S|$ pueden obtenerse fácilmente a partir de la igualdad

$$|S| = |A| / (N-1)^p$$

que $|A|$ puede escribirse

$$|A| = |\Sigma| \cdot |B| = |\Sigma| \cdot \chi^2_{N-1} \cdot \chi^2_{N-2} \dots \chi^2_{N-p}.$$

Puesto que el k -ésimo momento de una χ^2 con m grados de libertad es $2^m \Gamma\left(\frac{1}{2}(m+k)\right) / \Gamma\left(\frac{1}{2}m\right)$, el momento de un producto de variables aleatorias independientes es el producto de los momentos, el k -ésimo momento de $|A|$ es

$$\left| \sum_{i=1}^p \prod_{j=i+1}^p \left\{ 2^{\frac{1}{2}(N-i)} \frac{\Gamma\left(\frac{1}{2}(N-i)+k\right)}{\Gamma\left(\frac{1}{2}(N-i)\right)} \right\} \right|^k = 2^{kp} |\Sigma|^k \frac{\prod_{i=1}^p \prod_{j=1}^{\frac{1}{2}(N-i)+k_i}}{\prod_{i=1}^p \prod_{j=1}^{\frac{1}{2}(N-i)}}.$$

Así

$$E[|A|] = |\Sigma| \prod_{i=1}^p (N-i),$$

$$\text{var}(|A|) = |\Sigma|^2 \prod_{i=1}^p (N-i) \left[\prod_{j=1}^p \Gamma(N-j+2) - \prod_{j=1}^p \Gamma(N-j) \right].$$

En el caso $p=1$ y $p=2$, podemos dar la distribución de $V = |A|/|\Sigma|$. Para $p=1$, V se distribuye como una χ^2 con $N-1$ grados de libertad. Para $p=2$, encontramos que el momento $k/2$ de V es

$$E[V^{k/2}] = 2^k \frac{\Gamma\left(\frac{1}{2}(N-1)+k/2\right) \Gamma\left(\frac{1}{2}(N-2)+k/2\right)}{\Gamma\left(\frac{1}{2}(N-1)\right) \cdot \Gamma\left(\frac{1}{2}(N-2)\right)}$$

Utilizando la fórmula de la duplicación para las funciones gamma,

$$2^{2x-1} \Gamma(x) \cdot \Gamma(x + \frac{1}{2}) = \sqrt{\pi} \Gamma(2x)$$

obtenemos como expresión para el momento $k/2$ de V

$$E[V^{k/2}] = \frac{\Gamma(N-2+k)}{\Gamma(N-2)}$$

que es el momento k -ésimo de $1/2$ de una variable con la distribución χ^2 con $2N-4$ grados de libertad. Veámonos el siguiente teorema:

TEOREMA DE CARLEMAN. - Si $\{\mu_i\}$ ($i=1, 2, \dots$) es una sucesión de números tales que

$$\sum_{k \geq 1} \left(\frac{1}{\mu_{2k}} \right)^{1/2k}$$

es divergente, entonces al menos un distribución tiene la sucesión de momentos $\{\mu_i\}$.

La demostración puede encontrarse en Shohat y Tamarkin (1943) (The problem of the moments N.Y., A.M.S.). Utilizando el criterio de divergencia

$$\left(\frac{1}{\mu_{2k}} \right)^{1/2k} > \frac{1}{N-3+2k} > C \frac{1}{k}$$

para un $C (>0)$ adecuado y para k suficientemente grande, podemos verificarn que las condiciones del teorema anterior se satisfacen para los momentos de VV . Así VV se distribuye como un χ^2 con $2N-4$ grados de libertad.

Una aproximación a la densidad de $V^{1/p}$ viene dada por (Hoel, 1937)

$$\frac{C^{\frac{1}{2} p(N-p)}}{\Gamma\left(\frac{1}{2} p(N-p)\right)} e^{-cy} \approx e^{-cy}$$

donde

$$C = \frac{p}{2} \left(1 - \frac{(p-1)(p-2)}{2N} \right)^{N/p}.$$

La distribución asintótica de la varianza generalizada

Sea $|B|/n^p = V_1(n), V_2(n), \dots, V_p(n)$, donde las V_i 's se distribuyen independientemente y $nV_i(n) = \chi^2_{n-p+i}$. Puesto que χ^2_{n-p+i} se distribuye como $\sum_{\alpha=1}^{n-p+i} W_\alpha^2$, una las W_α independientes y $N(0,1)$, el teorema central del límite (aplicado a W_α^2) establece que

$$\frac{nV_i(n) - (n-p+i)}{\sqrt{2(n-p+i)}} = \sqrt{n} \frac{V_i(n) - 1 + \frac{p-i}{n}}{\sqrt{2} \sqrt{1 - \frac{p-i}{n}}}$$

se distribuye asintóticamente como $N(0,1)$. Entonces $\sqrt{n}[V_i(n) - 1]$ se distribuye asintóticamente como $N(0,2)$. Sea ahora

$$U(n) = \begin{pmatrix} V_1(n) \\ \vdots \\ V_p(n) \end{pmatrix}, \quad b = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}, \quad \text{y} \quad \sqrt{n}(U(n) - b)$$

que se distribuye asintóticamente como $N(0, T)$, siendo $T = 2I$. Definimos ahora $|B|/n^p = w = f(U_1, \dots, U_p) = U_1 U_2 \dots U_p$, siendo $\frac{\partial f}{\partial U_i} \Big|_{U=b} = 1$ y $\Phi'_b T \Phi_b = 2p$. Aplicando ahora el teorema límite ya utilizado cuando estudiábamos la tasa de formación χ^2 de Fisher para coeficientes de correlación, obtenemos

$$\sqrt{n} \left(\frac{|B|}{n^p} - 1 \right)$$

se distribuye asintóticamente como $N(0, 2p)$.

Teorema. - Sea S una matriz de covarianzas muestral de orden p con n grados de libertad. Entonces $\sqrt{n} \left(|S|/|T| - 1 \right) \rightarrow$ asintóticamente normal con media 0 y varianza $2p$.

6. DISTRIBUCIÓN DE UN CONJUNTO DE COEFICIENTES DE CORRELACIÓN PARA UNA MATRIZ DE COVARIANZAS POBLACIONAL DIAGONAL.

67

En el momento anterior la distribución para un coeficiente de correlación simple es nula cuando la correspondiente correlación poblacional sea cero. Aquí vamos a encontrar la densidad para el conjunto $r_{ij} | i \neq j, i,j=1-p$, cuando $\rho_{ij}=0$, $i \neq j$.

Convenzamos studiando la distribución de A cuando Σ es diagonal, es decir $W((\delta_{ii}\delta_{jj}), n)$. La densidad de A es

$$\frac{|\alpha_{ij}|^{\frac{1}{2}(n-p-1)} \exp\left(-\frac{1}{2} \sum_{i=1}^p \frac{\alpha_{ii}}{\delta_{ii}}\right)}{2^{\frac{1}{2}np} \pi^{\frac{1}{4}p(p-1)} \prod_{i=1}^p \delta_{ii}^{\frac{1}{2}n} \prod_{i=1}^p \Gamma\left(\frac{1}{2}(n+1-i)\right)}$$

puesto que

$$|\Sigma| = \begin{vmatrix} \delta_{11} & 0 & \dots & 0 \\ 0 & \delta_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \delta_{pp} \end{vmatrix} = \prod_{i=1}^p \delta_{ii}$$

Hacemos la transformación

$$(1) \quad \alpha_{ij} = \sqrt{\delta_{ii}} r_{ij} \delta_{jj} \quad i \neq j$$

$$(2) \quad \alpha_{ii} = \delta_{ii}$$

El Jacobiano de esta transformación viene dado por el producto del Jacobiano de (2) por el Jacobiano de (1) para α_{ii} fijo. El Jacobiano de (1) es el determinante de una matriz diagonal de orden $p(p-1)/2$ cuyos elementos en la diagonal principal son $\sqrt{\delta_{ii}} r_{ij} \delta_{jj}$. Puesto que cada índice, por ejemplo k_1 , aparece en el conjunto $r_{ij}, i \neq j, p-1$ veces, el Jacobiano es

$$J = \prod_{i=1}^p \alpha_{ii}^{\frac{1}{2}(p-1)}$$

Sustituyendo en la densidad de A obtenemos la densidad conjunta de $\{\alpha_{ij}\}$ y $\{r_{ij}\}$

$$\frac{|\sqrt{\delta_{ii}} r_{ij} \delta_{jj} \alpha_{ij}|^{\frac{1}{2}(n-p-1)} \cdot \exp\left(-\frac{1}{2} \sum_{i=1}^p \frac{\alpha_{ii}}{\delta_{ii}}\right)}{2^{\frac{1}{2}np} \pi^{\frac{1}{4}p(p-1)} \prod_{i=1}^p \delta_{ii}^{\frac{1}{2}n} \prod_{i=1}^p \Gamma\left(\frac{1}{2}(n+1-i)\right)} \prod_{i=1}^p \alpha_{ii}^{\frac{1}{2}(p-1)} = \frac{|r_{ij}|^{\frac{1}{2}(n-p-1)}}{\pi^{\frac{1}{4}p(p-1)} \prod_{i=1}^p \Gamma\left[\frac{1}{2}(n+1-i)\right]} \prod_{i=1}^p \left\{ \frac{\alpha_{ii}^{\frac{1}{2}n-1} \cdot \exp\left(-\frac{1}{2} \frac{\alpha_{ii}}{\delta_{ii}}\right)}{2^{\frac{1}{2}n} \delta_{ii}^{\frac{1}{2}n}} \right\}$$

puesto que

$$|\sqrt{\delta_{ii}} r_{ij} \delta_{jj}| = \left(\prod_{i=1}^p \alpha_{ii} \right) |r_{ij}|$$

donde $r_{ii}=1$. En el denominador del producto del miembro derecho de la igualdad obtenida el signo de la constante, hagamos $\alpha_{ii}/(\delta_{ii}) = u_i$; entonces la integral de estos términos es

$$\int_0^\infty \frac{\alpha_{ii} \cdot \exp\left(-\frac{1}{2} \frac{\alpha_{ii}}{\delta_{ii}}\right)}{2^{\frac{1}{2}n} \delta_{ii}^{\frac{1}{2}n}} d\alpha_{ii} = \int_0^\infty u_i^{\frac{1}{2}n-1} e^{-u_i} du_i = \Gamma\left(\frac{1}{2}n\right)$$

por la definición de la función Γ (obtenido por el hecho de que α_{ii}/δ_{ii} tiene una densidad χ^2 con n grados de libertad). Por tanto la densidad de r_{ij} es

$$\frac{\left[\Gamma\left(\frac{1}{2}n\right) \right]^p |r_{ij}|^{\frac{1}{2}(n-p-1)}}{\prod_{i=1}^p \Gamma\left(\frac{1}{2}(n+1-i)\right) \pi^{\frac{1}{4}p(p-1)}}$$

TEOREMA. - Si X_1, \dots, X_n son n independientes, cada una con distribución $N(\mu_j, (\delta_{ii}\delta_{jj}))$, entonces la densidad de los coeficientes de correlación muestrales viene dada por la fórmula anterior, donde $n=N-1$.