

ANALISIS ESTADISTICO MULTIVARIANTE Y REPRESENTACION CANONICA DE FUNCIONES ESTIMABLES



**TESIS PARA OPTAR AL GRADO
DE DOCTOR EN CIENCIAS, SECCION
DE MATEMATICAS, PRESENTADA POR**

CARLOS M. CUADRAS AVELLANA

Recíprocamente, si $P = X' \Delta X D_1$, para un cierto D_1 , entonces, tomando $\hat{D} = \Delta X D_1$, se verificará $P = X' \hat{D}$.

Además, \hat{D} es único, pues si $P = X' \Delta X \bar{D}_1$, siendo $\bar{D}_1 = D_1 + V$, y $V' X' \Delta X = 0$, entonces, por ser $S = T$, tendremos $V' X' = 0$, y por lo tanto

$$\hat{D} = \Delta X \bar{D}_1 = \Delta X (D_1 + V) = \Delta X D_1 = \hat{D}$$

c. q. d.

Teorema 4.5.1

Sea $\psi^* = P' \beta^* = p_1 \beta_1^* + \dots + p_m \beta_m^*$ una función paramétrica estimable. Sea $\hat{\beta}$ una estimación LS de β^* .

1) El estimador lineal

$$\hat{\psi} = P' \hat{\beta} = p_1 \hat{\beta}_1 + \dots + p_m \hat{\beta}_m$$

es un estimador insesgado y de dispersión mínima de ψ^* (Teorema de Gauss-Markov).

2) Si $\hat{D} = (\hat{d}_1, \dots, \hat{d}_k)'$ verifica:

$$\hat{D} = \Delta X D_1, \quad \text{siendo} \quad P' = X' \Delta X D_1,$$

entonces

$$\psi^* = \sum_{i=1}^k \hat{d}_i m_i^*$$

es la expresión Δ -óptima de ψ^* .

Demostración:

Por ser ψ^* estimable, $P' = X' D$, y por el lema anterior $P = X' \Delta X D_1$ para un cierto vector D_1 .

Si $\hat{\beta}$ es una estimación LS de β^* ,

$$P' \hat{\beta} = D_1' X' \Delta X \hat{\beta} = D_1' X' \Delta \bar{\pi}^* = \hat{D}' \bar{\pi}^*$$

siendo $\hat{D} = \Delta X D_1 = (\hat{d}_1, \dots, \hat{d}_k)'$, que por el lema anterior, es único.

Al ser $X' \hat{D} = X' \Delta X D_1 = P$, por el teorema 4.3.2 tendremos

$$\hat{\Psi} = P' \hat{\beta} = D' \bar{\Pi} = \sum_{i=1}^k \hat{d}_i \bar{\rho}_i$$

y Ψ^* admite la expresión

$$\Psi^* = \sum_{i=1}^k \hat{d}_i m_i^*$$

Luego $E^*(\hat{\Psi}) = \Psi^*$, y $\hat{\Psi}$ es estimador insesgado. Veamos que es de dispersión mínima, es decir, que la expresión

$$\Psi^* = \sum_{i=1}^k \hat{d}_i m_i^* \text{ es } \Delta\text{-óptima.}$$

Sea

$$\hat{\Psi}_1 = \sum_{i=1}^k d_i \bar{\rho}_i = D' \bar{\Pi}$$

otro estimador insesgado, siendo $P = X'D$. El producto escalar en N de $(\hat{\Psi}_1 - \hat{\Psi})$ y $\hat{\Psi}$ es:

$$\begin{aligned} (\hat{\Psi}_1 - \hat{\Psi}) \cdot \hat{\Psi} &= (\hat{D}' - D') \Delta^{-1} \hat{D} = (\hat{D}' - D') \Delta^{-1} \Delta X D_1 = \\ &= (\hat{D}' X - D' X) D_1 = (P' - P') D_1 = 0 \end{aligned}$$

$$\text{Luego: } \|\hat{\Psi}_1\|^2 = \|\hat{\Psi}_1 - \hat{\Psi} + \hat{\Psi}\|^2 = \|\hat{\Psi}_1 - \hat{\Psi}\|^2 + \|\hat{\Psi}\|^2 \geq \|\hat{\Psi}\|^2$$

c. q. d.

Este teorema nos proporciona dos maneras de hallar la estimación óptima $\hat{\Psi}$ de la función paramétrica $\Psi^* = P' \beta^*$

a) Hallando la estimación $\hat{\beta}$ de los parámetros resolviendo las ecuaciones normales, y entonces $\hat{\Psi} = P' \hat{\beta}$.

b) Hallando D_1 tal que $P' = X' \Delta X D_1$, y a continuación $\hat{D} = \Delta X D_1$, que nos da la expresión Δ -óptima $\Psi^* = \sum_i \hat{d}_i m_i^*$.
Entonces:

$$\hat{\Psi} = \hat{d}_1 \bar{\rho}_1 + \dots + \hat{d}_k \bar{\rho}_k$$

5

HIPOTESIS LINEALES Y COMPARACION ESTADISTICA DE FUNCIONES ESTIMABLES

Se expone la estimación de la matriz de varianzas-covarianzas, siguiendo las notaciones de RAO (1965), el test estadístico de comparación de funciones estimables, basándonos en el principio de unión-intersección de ROY (1957), y algunos otros resultados de análisis multivariante

El contenido de este capítulo es materia bien conocida. Su inclusión se justifica por la necesidad que de él tendremos más adelante, y por el deseo de conseguir una completa unidad de exposición de la memoria.

Otras referencias: ANDERSON(1958), MORRISON(1967), RAO(1951), ROY(1953,1966).

5.1. PROPIEDADES DE LAS ESTIMACIONES LS

Sea $Y \in E$ una v.a. tal que $\text{var}(Y) = \sigma^2$. Para no perder grados de libertad, vamos a considerar aquí los $n = \sum n_i$ valores muestrales de un muestreo $\Delta = (n_1, \dots, n_k)$ de Y . Indicaremos la muestra mY y el vector aleatorio $Y^{(n)}$, abreviadamente,

$$mY = (y_1, \dots, y_n) \quad Y^{(n)} = (Y^1 \dots Y^n)$$

Sea E_Y^n el espacio vectorial de dimensión n ,

$$E_Y^n = \langle Y^1, \dots, Y^n \rangle$$

con base ortonormal, justificado por el hecho de que las v.a. $\{Y^i\}$ son estocásticamente independientes.

Consideremos ahora un espacio vectorial euclídeo E_n de dimensión n . Una muestra $mY = (y_1, \dots, y_n)$ de cualquier v.a. Y , se puede identificar con un punto de E_n . El muestreo $m \in m_\Delta$, define, pues, una aplicación:

$$m: E_Y^n \longrightarrow E_n$$

$$m(Y^{(n)}) = mY \quad \forall Y \in E$$

Asimismo, la esperanza matemática ξ define una aplicación:

$$\xi: E_Y^n \longrightarrow E_n$$

$$(5.1.1) \quad \xi(Y^{(n)}) = \lambda_a \beta_Y$$

Consideremos ahora el subespacio $F_r \subset E_n$, generado por los vectores columna de λ_a . Tendremos,

$$\dim(F_r) = \text{rang}(X) = r$$

Observemos, finalmente, que para toda v.a. Y , la estructura métrica de los espacios E_Y^n y E_n , ambos con base ortonormal, es la misma, y se pueden identificar totalmente.

Teorema 5.1.1

Sea Y una v.a. de E . Se verifica:

$$1) \xi(Y^{(n)}) \in F_r$$

2) Cualquiera que sea el muestreo $m \in m_\Delta$

$$(\xi(Y^{(n)}) - mY) \perp (\chi_a \hat{\beta}_Y - mY)$$

es ortogonal al subespacio F_r .

Demostración:

1) Por (5.1.1), las componentes de la imagen de $Y^{(n)}$ por ξ son combinación lineal de los vectores columna de χ_a .

2) De las ecuaciones normales (4.4.4), deducimos:

$$\chi_a' (\chi_a \hat{\beta}_Y - mY) = 0$$

de donde $(\chi_a \hat{\beta}_Y - mY)$ es ortogonal a F_r .

5.2. ESTIMACION DE LA MATRIZ Σ

De la misma manera que los individuos medios y su extensión, las funciones estimables, son, en la práctica, desconocidas, también lo es la matriz Σ de varianzas-covarianzas, común a las poblaciones H_i ($i=1, \dots, k$).

Sea P una matriz de orden (n, n) , de modo que sus vectores columna $(P_1, \dots, P_r, P_{r+1}, \dots, P_n)$ sean ortonormales, y los r primeros pertenezcan al subespacio F_r generado por los vectores de componentes las columnas de χ_a .

La matriz P define un cambio de base isométrico

$$Y^{(n)} = (Y^1, \dots, Y^n) \xrightarrow{P} (Z^1, \dots, Z^n) = Z^{(n)}$$

$$Z^i = p_{i1} Y^1 + \dots + p_{ni} Y^n \quad i=1, \dots, n$$

Se verifica:

$$(5.2.1) \quad \begin{aligned} \mathcal{E}(Z^i) &= P_i^i \mathcal{E}(Y^{(n)}) = 0 \quad \text{si } i > r \quad (\text{por el teo-} \\ &\quad \text{rema 5.1.1)}. \\ \mathcal{E}(Z^i) &= \zeta_i \quad \text{si } i \leq r \end{aligned}$$

Sea ahora:

$$\begin{aligned} \mathcal{L}(\hat{\beta})(Y) &= \sum_{i=1}^n (y_i - \sum_{j=1}^m x_{ji} \beta_{Yj})^2 = \\ &= \|mY - X_a \hat{\beta}_Y\|^2. \end{aligned}$$

de acuerdo con la norma que rigen en E_n .

Según el teorema 5.1.1, $(mY - X_a \hat{\beta}_Y)$ es ortogonal al subespacio F_r , luego,

$$(5.2.2) \quad \mathcal{L}(\hat{\beta})(Y) = \sum_{i=r+1}^n Z_i^2$$

siendo $mZ = (z_1, \dots, z_r, z_{r+1}, \dots, z_n)$ el muestreo sobre $Z^{(n)}$, expresión en la nueva base dual $\{(Z^i)^*\}$ que la matriz ortonormal P define sobre $E_{Y^*}^n$.

Puesto que (5.2.2) es cierta para toda muestra, considerando $\mathcal{L}(\hat{\beta})(Y)$ como una variable aleatoria, tendremos

$$\mathcal{L}(\hat{\beta})(Y) = \sum_{i=1}^n (Y^i - \sum_{j=1}^m x_{ji} \beta_{Yj})^2 = \sum_{i=r+1}^n (Z^i)^2$$

y, tomando la esperanza,

$$\mathcal{E}(\mathcal{L}(\hat{\beta})(Y)) = \sum_{i=r+1}^n \mathcal{E}[(Z^i)^2] = (n-r)\sigma^2$$

pues, por (5.2.1), $\mathcal{E}[(Z^i)^2] = \sigma^2$.

Teorema 5.2.1

La v.a.:

$$\mathcal{L}(\hat{\beta}_Y)(Y)/(n-r)$$

es un estimador insesgado de $\sigma^2 = \text{var}(Y)$,

$$\mathcal{E}[\mathcal{L}(\hat{\beta}_Y)(Y)/(n-r)] = \sigma^2$$

Este teorema nos proporciona, en particular, la estimación de cada una de las varianzas de las v.a. Y_1, \dots, Y_p que forman la base de E . Indicaremos:

$$R_o(i, i) = \mathcal{L}(\hat{\beta})(Y_i) \quad \sigma_{ii} = \text{var}(Y_i)$$

Propongámonos ahora, la estimación de $\sigma_{ij} = \text{cov}(Y_i, Y_j)$.

$$\text{Sea } Y = Y_i + Y_j, \quad R_o^2 = \mathcal{L}(\hat{\beta})(Y)$$

Entonces, si $R_o(i, j)$ es el producto escalar de las proyecciones de (mY_i) y (mY_j) en F_r , tendremos:

$$R_o^2 = R_o(i, i) + R_o(j, j) + 2 R_o(i, j)$$

siendo, en expresión matricial,

$$R_o(i, j) = (mY_i - X_a \hat{\beta}_{Y_i})' (mY_j - X_a \hat{\beta}_{Y_j})$$

Entonces,

$$\mathcal{E}(R_o^2) = (n-r)\text{var}(Y) = (n-r)(\sigma_{ii} + \sigma_{jj} + 2\sigma_{ij})$$

$$\Rightarrow \mathcal{E}(R_o(i, j)) = (n-r)\sigma_{ij}$$

Teorema 5.2.2

Sea R_o la matriz cuyos elementos son $R_o(i, j)$. Los elementos de la matriz

$$\hat{\Sigma} = \frac{1}{n-r} R_o$$

son estimadores insesgados de Σ .

5.3. HIPOTESIS LINEALES ESTADISTICAMENTE DEMOSTRABLES

Sean $\psi_1^*, \dots, \psi_s^*$ funciones paramétricas estimables, linealmente independientes, siendo $s \leq r = \text{rang}(X) = \dim M$.

El principal objetivo de esta memoria es establecer una forma sencilla de diferentes funciones estimables, para lo cual necesitamos poder aceptar, con un nivel de significación α , que las s f.p.e. son realmente distintas.

Planteemos la hipótesis nula:

$$H_0: \psi_1^* = \psi_2^* = \dots = \psi_s^*$$

bajo la cual las s f.p.e. coinciden.

Puesto que las $t-s-1$ funciones paramétricas

$$\psi_{si}^* = \psi_s^* - \psi_i^* \quad i=1, \dots, t-1$$

son también estimables y linealmente independientes, (teorema 3.2.1), H_0 se expresa también así:

$$H'_0: \psi_{s1}^* = \dots = \psi_{st}^* = 0$$

Sea ahora

$$\psi_{si}^* = h_{i1} \beta_1^* + \dots + h_{im} \beta_m^* \quad i=1, \dots, s$$

e indiquemos por H la matriz

$$H = \begin{pmatrix} h_{11} & \dots & h_{1m} \\ \dots & \dots & \dots \\ h_{t1} & \dots & h_{tm} \end{pmatrix} \quad \text{rang } H = t$$

La hipótesis nula tiene una tercera expresión:

$$H''_0: H \cdot \beta = 0 \quad \mathcal{G}(H) \subset \mathcal{G}(X)$$

siendo $\mathcal{G}(H)$ y $\mathcal{G}(X)$ los subespacios generados por las filas de H y X respectivamente.

A esta última formulación de la hipótesis nula se la conoce como hipótesis lineales acerca de los parámetros β . Se dice que estas hipótesis son demostrables, (en el sentido de inferencia estadística), si $\mathcal{F}(H) \subset \mathcal{F}(X)$ (ROY, 1957). Equivalentemente, una comparación H_0 de funciones paramétricas es estadísticamente demostrable si las funciones son estimables.

5.4. TRANSFORMACION DE LOS PARAMETROS BAJO LA HIPOTESIS NULA

Si es cierta la hipótesis nula, existirán $t=s-1$ restricciones lineales, independientes, sobre los parámetros que nos permitirá pasar de m parámetros a $r-s+1$ nuevos parámetros.

Sea C' una matriz de orden $(r-s+1, m)$, tal que

$$(5.4.1) \quad H.C = 0 \quad \text{rang}(C) = r-s+1$$

Para obtener la matriz C' , basta completar las filas de H , con $r-s+1$ vectores ortogonales linealmente independientes.

El vector de parámetros $\theta = (\theta_1, \dots, \theta_{r-s+1})$ representa la solución general de la ecuación $H\beta = 0$, pues

$$H\beta = H.C\theta = 0$$

El diseño factorial (4.4.3), se transformará, en función de los nuevos parámetros, en:

$$(5.4.2) \quad \mathcal{E}(Y^{(n)}) = \chi_a C \theta_Y \quad \text{rang}(\chi_a C) = r-s+1$$

y la nueva matriz ampliada del diseño factorial, será $\chi_a C$. Al igual que en § 5.1, los vectores columna de esta matriz generan un subespacio F_{r-t} , siendo

$$F_{r-t} \subset F_r \subset E_n \quad (t=s-1)$$

Podemos aplicar toda la teoría de mínimos cuadrados del capítulo 4, para estimar los nuevos parámetros θ . Procediendo como en §5.2, podremos construir una base ortogonal en E_Y^n :

$$\langle Z^1, \dots, Z^t, Z^{t+1}, \dots, Z^r, Z^{r+1}, \dots, Z^n \rangle$$

de modo que

$$F_Y^{r-t} = \langle Z^{t+1}, \dots, Z^r \rangle \subset F_Y^r = \langle Z^1, \dots, Z^r \rangle$$

Además, dada una muestra mY ,

$$\mathcal{L}(\hat{\theta})(Y) = (mY - \lambda_a C)(mY - \lambda_a C)'$$

y, considerado como v.a. (§5.2),

$$(5.4.3) \quad \mathcal{L}(\hat{\theta})(Y) = \sum_{i=t+1}^r (Z^i)^2$$

Puesto que los parámetros θ provienen de β restringidos a H_0'' , pondremos:

$$\mathcal{L}(\hat{\theta})(Y) = \mathcal{L}(\hat{\beta})(Y) \\ H\beta = 0$$

5.5. UN TEOREMA FUNDAMENTAL PARA EL ANALISIS CANONICO

El siguiente teorema, de álgebra lineal, relativo a dos productos internos en un espacio vectorial, será fundamental en este capítulo y en los siguientes de la memoria. La demostración puede verse en DEMPSTER (1969, pg. 84).

Teorema fundamental

Sea V un espacio vectorial de dimensión p , y sean π_0 y π_1 dos productos escalares en V , de matrices asociadas A_0 y A_1 , con π_0 definido positivo y $\text{rang}(A_1) = q \leq p$.

Sean $\{\lambda_i\}$ y $\{V_i\}$ ($i=1, \dots, q$), los valores propios y vectores propios de A_1 relativos a A_0 , es decir, tales que:

$$A_1(V_i) = \lambda_i A_0(V_i) \quad i=1, \dots, q$$

siendo $\lambda_1 > \lambda_2 > \dots > \lambda_q$.

Entonces, V_1 es el vector de V que hace máximo al cociente de módulos al cuadrado, $(V, V)_1 / (V, V)_0$, y este máximo es λ_1 ,

$$\lambda_1 = \frac{(V_1, V_1)_1}{(V_1, V_1)_0} = \max_{V \in V} \frac{(V, V)_1}{(V, V)_0}$$

Del subespacio ortocomplementario a V_1 , V_2 maximiza el cociente anterior, y el valor máximo es λ_2 ,

$$\lambda_2 = \frac{(V_2, V_2)_1}{(V_2, V_2)_0} = \max_{V \in \{V_1\}^\perp \subset V} \frac{(V, V)_1}{(V, V)_0}$$

y así sucesivamente con V_3, \dots, V_q .

Aplicaremos en este capítulo, el teorema fundamental a los dos productos escalares que $\mathcal{L}(\hat{\beta})$ y $\mathcal{L}(\hat{\theta})$ definen sobre E .

Sea $m \in \mathcal{M}$ un muestreo. Definimos:

$$\mathcal{L}_m(\hat{\beta})(Y, \bar{Y}) = (mY - X_a \hat{\beta})(m\bar{Y} - X_a \hat{\beta}),$$

$$\mathcal{L}_m(\hat{\theta})(Y, \bar{Y}) = (mY - X_a C \hat{\theta})(m\bar{Y} - X_a C \hat{\theta}).$$

La matriz asociada al producto escalar $\mathcal{L}_m(\hat{\beta})$ es R_0 (§5.2). Indicaremos por R_1 , la matriz asociada a $\mathcal{L}_m(\hat{\theta})$,

$$R_1 = (R_1(i, j)) \quad \text{siendo} \quad R_1(i, j) = \mathcal{L}_m(\hat{\theta})(Y_i, Y_j).$$

Para un determinado muestreo m , las matrices R_0 y R_1 , son fijas. Consideradas como funciones de m son matrices aleatorias.

5.6. TEST ESTADISTICO DE COMPARACION DE FUNCIONES ESTIMABLES SUPONIENDO NORMALIDAD

En este apartado supondremos que la distribución conjunta de las v.a. (Y_1, \dots, Y_p) , es normal multivariante en cada celda H_i ($i=1, \dots, k$).

$$(Y_1, \dots, Y_p) \text{ es } N((\xi(Y_1), \dots, \xi(Y_p)), \Sigma) \text{ en } H_i \quad (i=1, \dots, k)$$

5.6.1. Caso univariante

Sea $Y = \sum_{h=1}^n a_h Y_h$ una v.a. de E. La distribución de Y en la celda o población H_i es normal (univariante). Planteemos la hipótesis nula relativa a la v.a. Y ,

$$H_{0Y}: \psi_1^*(Y) = \dots = \psi_s^*(Y)$$

Teorema 5.6.1

Sea $\sigma^2 = \text{var}(Y)$

1) La v.a.:

$$\frac{\mathcal{L}(\hat{\beta})(Y)}{\sigma^2} = \frac{\text{mín } \mathcal{L}(\beta)(Y)}{\sigma^2}$$

sigue una distribución ji-cuadrado con $n-r$ grados de libertad.

2) Bajo H_{0Y} , la v.a.:

$$\frac{1}{\sigma^2} \mathcal{L}(\hat{\theta})(Y) = \frac{1}{\sigma^2} \mathcal{L}(\hat{\beta})(Y) \quad H: \beta = 0$$

sigue una distribución ji-cuadrado con $n-t=n-s+1$ g. de libertad.

3) Bajo H_{0Y} , las v.a.:

$$\mathcal{L}(\hat{\beta})(Y) \text{ y } (\mathcal{L}(\hat{\theta})(Y) - \mathcal{L}(\hat{\beta})(Y))$$

son estocásticamente independientes.

Demostración:

La distribución conjunta de las v.a.:

$$Z^1, \dots, Z^t, Z^{t+1}, \dots, Z^r, Z^{r+1}, \dots, Z^n \quad (t=s-1)$$

introducidas en § 5.4, es normal multivariante, y, puesto que son incorrelacionadas, tales v.a. serán estocásticamente independientes. Según § 5.2, tenemos:

$$\mathcal{L}(\hat{\beta})(Y) = \sum_{i=r+1}^n (Z^i)^2, \quad \xi(Z^i) = 0$$

$$\text{var}(Z^i) = \sigma^2 \quad i=r+1, \dots, n.$$

y de aquí deducimos 1) Análogamente, bajo H_0

$$\mathcal{L}(\hat{\theta})(Y) = \sum_{i=t+1}^n (Z^i)^2, \quad \xi(Z^i) = 0$$

$$\text{var}(Z^i) = \sigma^2 \quad i=t+1, \dots, n.$$

Finalmente,

$$\mathcal{L}(\hat{\theta})(Y) - \mathcal{L}(\hat{\beta})(Y) = \sum_{i=t+1}^n (Z^i)^2$$

es una v.a. en la que no aparece ninguna Z^i que esté también en $\mathcal{L}(\hat{\beta})(Y)$, luego es independiente de $\mathcal{L}(\hat{\beta})(Y)$.

c. q. d.

Corolario 5.6.1

Bajo la hipótesis H_0 , la v.a.:

$$F_Y = \frac{(\mathcal{L}(\hat{\theta})(Y) - \mathcal{L}(\hat{\beta})(Y)) / (r-s+1)}{\mathcal{L}(\hat{\beta})(Y) / (n-r)}$$

sigue una distribución F, con $(r-s+1)$ y $(n-r)$ g. de l.

Elegido un nivel de significación α , el test se resuelve hallando F_α tal que

$$P(F > F_\alpha) = \alpha, \quad F \text{ con } (r-s+1) \text{ y } (n-r) \text{ g. de l.}$$

Rechazaremos H_{0Y} , si $F_Y > F_\alpha$, con probabilidad α de equivocarnos, y aceptaremos H_{0Y} , si $F_Y \leq F_\alpha$.

5.6.2. Caso multivariante

De acuerdo con las métricas de matrices asociadas R_0 y R_1 (§5.5), pongamos:

$$\mathcal{L}(\hat{\beta})(Y) = \|Y\|_0^2 \quad \mathcal{L}(\hat{\delta})(Y) = \|Y\|_1^2$$

Planteemos ahora la hipótesis nula:

$$H_0: \quad \psi_1^* = \dots = \psi_s^*$$

Se verifica:

$$H_0 = \bigcap_{Y \in E} H_{0Y}$$

es decir, aceptar H_{0Y} , para toda Y , equivale a aceptar H_0 (principio de unión-intersección de ROY, 1957).

Para una v.a. $Y \in E$, sea:

$$\lambda(Y) = \frac{\|Y\|_1^2}{\|Y\|_0^2}$$

El valor F para esta v.a. es:

$$F_Y = \frac{(\|Y\|_1^2 - \|Y\|_0^2) / (r-s+1)}{\|Y\|_0^2 / (n-r)} = (\lambda(Y) - 1) \frac{(n-r)}{(r-s+1)}$$

Aceptaremos H_{0Y} si $F_Y \leq F_\alpha$, y aceptaremos H_0 si esto es cierto para toda $Y \in E$. Busquemos pues, para toda $Y \in E$,

$$F = \max F_Y = (\lambda_1 - 1) \frac{n-r}{r-s+1}$$

siendo $\lambda_1 = \max \frac{\|Y\|_1^2}{\|Y\|_0^2}$

Según el teorema fundamental, λ_1 es la mayor raíz de la ecuación matricial

$$(5.6.1) \quad \det (R_1 - \lambda R_0) = 0$$

En principio, pues, aceptamos H_0 si

$$F = \max F_Y \leq F_\alpha$$

En realidad F , que es función de λ_1 , no sigue la distribución F de Fisher, si lo consideramos pendiente del muestreo sobre las p v.a. (excepto si $p \leq 2$). Para resolver correctamente el test, deberíamos conocer la distribución exacta de λ_1 .

Se puede resolver también utilizando todas las raíces de la ecuación (5.3.1), definiendo el estadístico

$$\Lambda = \frac{\det(R_0)}{\det(R_1)} = (\lambda_1 \cdot \lambda_2 \cdots \lambda_p)^{-1}$$

que sigue una distribución $U_{p, r-t, n-r}$ (WILKS, 1932), siendo p el nº de v.a., $r-t$ y $n-r$ el nº de grados de libertad.

En efecto: (véase RAO, 1965) Λ es el cociente de determinantes de dos matrices con distribuciones de Wishart independientes.

$$R_0 \text{ es } W(n-r, \Sigma)$$

$$R_1 - R_0 \text{ es } W(r-t, \Sigma) \quad R_1 = (R_1 - R_0) + R_0 \text{ es } W(n-t, \Sigma)$$

La distribución de Λ coincide con la distribución del producto de variables aleatorias independientes con distribución beta.

Bajo H_0 , y en algunos casos particulares, la distribución de Λ coincide con la distribución F de Fisher:

$(t=s-1)$

$$r-t=1 \quad F = \frac{1-\Lambda}{\Lambda} \frac{n-t-p}{p} \quad p, n-t-p \quad \text{g. de l.}$$

$$r-t=2 \quad F = \frac{1-\sqrt{\Lambda}}{\sqrt{\Lambda}} \frac{n-t-p-1}{p}, \quad 2p, 2(n-p-t-1) \quad \text{g. de l.}$$

$$p=1 \quad F = \frac{1-\Lambda}{\Lambda} \frac{n-r}{r-t} \quad r-t, n-r \quad \text{g. de l.}$$

$$p=2 \quad F = \frac{1-\sqrt{\Lambda}}{\sqrt{\Lambda}} \frac{n-r-1}{r-t} \quad 2(r-t), 2(n-r-1) \quad \text{g. de l.}$$

(véase ANDERSON, 1958).

Para los demás casos, puede utilizarse la propiedad asintótica (RAO, 1951) del estadístico:

$$F = \frac{1-\Lambda^{1/s}}{\Lambda^{1/s}} \frac{ms-2\lambda}{p(r-t)}$$

siendo:

$$m = n-t - \frac{p+r-t+1}{2}$$

$$s = \frac{\sqrt{p^2(r-t)^2 - 4}}{\sqrt{p^2 + (r-t)^2 - 5}}$$

$$\lambda = \frac{p(r-t) - 2}{4}$$

que, bajo H_0 , converge en ley a la distribución F con

$p(r-t)$, $ms-2\lambda$ grados de libertad

cuando n tiende a infinito.

Respecto a la potencia del test, véase, por ejemplo, ROY(1966).

6

ANALISIS CANONICO DE POBLACIONES

Presentamos en este capítulo el análisis canónico de RAO (1952), basándonos en la exposición de COOLEY y LOHNES (1962,1971) y SEAL (1964). Las notaciones se apoyan en el álgebra lineal, siguiendo la tónica de los capítulos anteriores.

Se incluye una aportación que puede ser interesante: la obtención de una región confidencial exacta para representar a cada una de las poblaciones en el espacio canónico. Puede sustituir con ventaja a la región aproximada que se viene utilizando (SEAL,1964,pág.137).

Se ha consultado también: ANDERSON(1958), DEMPSTER(1969), FISHER (1936,1950), GOODMAN(1972), HOPE(1972), KENDALL(1957), MORRISON(1967).

6.1. PARAMETRIZACIONES

Cuando el sistema de funciones estimables son los k individuos medios de las k poblaciones, podemos introducir $m=k$ parámetros tales que,

$$m_1^* = \beta_1^*, \dots, m_k^* = \beta_k^*$$

La matriz del diseño factorial X es entonces la matriz identidad. Tendremos:

$$(6.1.1) \quad m_i^*(Y) = 0 \cdot \beta_{Y1} + \dots + 1 \cdot \beta_{Yi} + \dots + 0 \cdot \beta_{Ym} \quad Y \in E$$

En particular, para las v.a. Y_j ,

$$m_i^*(Y_j) = \beta_{ji} \quad i=1, \dots, k; \quad j=1, \dots, p.$$

Con la parametrización (6.1.1), toda función paramétrica es estimable. (Corolario 4.3.2).

Puede utilizarse también otra parametrización:

$$(6.1.2) \quad m_i^*(Y) = \mu + \alpha_i \quad i=1, \dots, k \quad Y \in E$$

en la que intervienen $m=k+1$ parámetros, representando μ la media general, y α_i el efecto de grupo de la variable Y , población i .

En esta parametrización, una función estimable será:

$$\begin{aligned} \psi^* &= \sum_I c_i m_i^* = \sum_I c_i \sum_J (\mu_j + \alpha_{ji}) Y_j^* = \\ &= \sum_J \left(\left(\sum_I c_i \right) \mu_j + \sum_I c_i \alpha_{ji} \right) Y_j^* \end{aligned}$$

es decir, para que una función paramétrica sea estimable es necesario y suficiente que los coeficientes que afectan a cada μ_j , sean suma de los k coeficientes que afectan a los efectos de grupo α_{ji} .

La parametrización (6.1.2) será generalizada en el próximo capítulo. Aquí nos interesa analizar la estruc-

tura de los k individuos medios, en el caso $\dim M = k$, que en particular son funciones paramétricas estimables

Utilizaremos, para este fin, la parametrización (6.1.1), en la que $\text{rang}(X) = m = k = \dim M$.

6.2. COMPARACION DE INDIVIDUOS MEDIOS

Aplicando la teoría general del capítulo anterior, exponeremos, brevemente, la estimación de Γ , y el test estadístico para contrastar la hipótesis nula

$$H_0: m_1^* = m_2^* = \dots = m_k^*$$

La hipótesis nula, planteada a través de los parámetros, es

$$H_0: \beta_{j1} = \dots = \beta_{jk} \quad (j=1, \dots, p)$$

Para un muestreo de tamaño $\Delta = (n_1, \dots, n_k)$, indiquemos:

$$mY_j = (y_{j11}, \dots, y_{j1n_1}, \dots, y_{jk1}, \dots, y_{jkn_k}) \quad j=1, \dots, p$$

Cada individuo paramétrico es función estimable, y la estimación de β_{Y_j} es:

$$\hat{\beta}_{Y_j} = (\hat{R}_{j1}, \dots, \hat{R}_{jm})$$

siendo

$$\hat{R}_{jt} = \bar{y}_{jt} = \frac{1}{n_t} \sum_{h=1}^{n_t} y_{jth}$$

La matriz ampliada del diseño factorial es:

$$X_a = \left(\begin{array}{cccccc} 1 & 0 & \dots & 0 & & \\ \vdots & \vdots & & \vdots & & \\ 1 & 0 & \dots & 0 & & \\ \vdots & \vdots & & \vdots & & \\ 0 & \dots & 0 & 1 & & \\ \vdots & & \vdots & \vdots & & \\ 0 & \dots & 0 & 1 & & \end{array} \right) \left. \begin{array}{l} \} n_1 \\ \\ \\ \\ \} n_k \end{array} \right\} \text{rang } X_a = k = m$$

de donde

$$R_0(i, j) = (mY_j - X_a \hat{\beta}_{Y_i})' (mY_j - X_a \hat{\beta}_{Y_j}) =$$

$$= \sum_{t=1}^k \sum_{h=1}^{n_t} (y_{ith} - \bar{y}_{it.}) (y_{jth} - \bar{y}_{jt.})$$

Si es válida la hipótesis H_0 , entonces

$$\beta_{j1} = \dots = \beta_{jm} = \beta_j$$

y la estimación de β_j es

$$\hat{\beta}_j = \bar{y}_{j..} = \frac{1}{n} \sum_t \sum_h y_{jth}$$

de donde,

$$R_1(i, j) = \min_{H_0} (mY_i - X_a \beta_{Y_i})' (mY_j - X_a \beta_{Y_j}) =$$

$$= \sum_{t=1}^k \sum_{h=1}^{n_t} (y_{ith} - \bar{y}_{i..}) (y_{jth} - \bar{y}_{j..})$$

Finalmente, obtenidos los valores propios de R_1 respecto a R_0 , resolviendo,

$$\det(R_1 - \lambda R_0) = 0$$

se calcula el estadístico F tal como se explica en §5.6

6.3. COVARIABILIDAD ENTRE POBLACIONES

Supongamos $\dim M = k$, es decir, los k individuos medios son M -linealmente independientes. Con un nivel de significación α , una condición necesaria es haber podido rechazar la hipótesis nula H_0 .

Vamos a introducir, de una forma natural, una nueva métrica en el e.v. E , que refleje la covariabilidad de las variables debida a las diferencias entre los individuos medios.

Basándonos en que cada celda o población queda definida por el correspondiente individuo medio, introducimos un espacio de probabilidades discreto $(\Omega_M, \mathcal{A}_M, P_M)$, siendo:

$$\Omega_M = \{m_1, \dots, m_k\}$$

$$\mathcal{A}_M = \mathcal{P}(\Omega_M)$$

$$P_M(m_i) = P(H_i) = p_i \quad i=1, \dots, k.$$

Este espacio es isométrico al subespacio de (Ω, \mathcal{A}, P) generado por las k celdas o poblaciones H_i ($i=1, \dots, k$).

De una forma natural podemos considerar que una v. a. Y de E , alcanza los siguientes valores sobre los átomos de \mathcal{A}_M

$$Y(m_1) = \beta_{Y1}, \dots, Y(m_k) = \beta_{Yk}$$

El producto escalar que proporciona la covarianza será:

$$(6.3.1) \quad Y \cdot Y' = \text{cov}_M(Y, Y') = \sum_{h=1}^k (\beta_{Yh} - \bar{\beta}_Y)(\beta_{Y'h} - \bar{\beta}_{Y'}) p_h$$

siendo

$$\bar{\beta}_Y = \sum_{h=1}^k p_h \beta_{Yh} = \xi_M(Y)$$

la esperanza matemática en \mathcal{R}_M .

El producto escalar (6.3.1) es un nuevo producto escalar definido sobre el espacio E . Indicaremos por Σ_E a la matriz de este producto escalar referido a la base $\langle Y_1, \dots, Y_p \rangle$. Se puede introducir, también por otro camino,

Sea \mathcal{F}_M el espacio vectorial, de dimensión k , generado por (m_1, \dots, m_k) , considerados como átomos de \mathcal{A}_M .

Definamos en \mathcal{F}_M un producto escalar de matriz

$$M_m = \begin{pmatrix} p_1 & & & \\ & \ddots & & \\ & & \ddots & \\ & & & p_k \end{pmatrix}$$

según la cual, la base de \mathcal{F}_M es ortogonal.

Sea entonces la aplicación

$$f_m: E \longrightarrow \mathcal{F}_M$$

$$f_m(Y) = (\beta_{Y1} - \bar{\beta}_Y) m_1 + \dots + (\beta_{Yk} - \bar{\beta}_Y) m_k$$

La matriz Σ_E es la matriz del producto escalar en \mathcal{F}_M de los p vectores $f_m(Y_1), \dots, f_m(Y_p)$.

Indicando:

$$B = \begin{pmatrix} \beta_{11} - \bar{\beta}_1, \dots, \beta_{p1} - \bar{\beta}_p \\ \dots \\ \beta_{1k} - \bar{\beta}_1, \dots, \beta_{pk} - \bar{\beta}_p \end{pmatrix}$$

se tiene:

$$(6.3.2) \quad \Sigma_E = B^t M_m B$$

El producto escalar (6.3.1), de matriz asociada (6.3.2) en la base de E , refleja la covariabilidad de las v.s. de E debida a las diferencias entre los grupos o poblaciones. Por otra parte, la matriz Σ representa la covariabilidad que existe dentro de cada población.

Teorema 6.3.1

Supongamos $\dim N = k$.

- 1) Si es cierta la hipótesis nula H_0 , entonces $\Sigma_E = 0$.
- 2) Si podemos rechazar la hipótesis nula, y los individuos medios son funciones paramétricas N -linealmente independientes, se verifica:

$$\text{rang}(\Sigma_E) = \min(p, k-1)$$

Demostración:

El rango de Σ_E coincidirá con el rango de B .

Si H_0 es cierta, $\beta_{ji} = \bar{\beta}_i$, y entonces $B=0$, lo que implica $\Sigma_E = 0$.

El rango por ^{nas}columna de B , es p como máximo. Sumando las filas previamente multiplicadas por p_1, p_2, \dots, p_k , detectamos una combinación lineal entre las mismas, es decir, el máximo rango por filas es $(k-1)$.

c. q. d.

6.4. ESTIMACION DE Σ Y Σ_E

Aplicando directamente la teoría general de §5.2 al modelo paramétrico (6.1.1), tendremos que los elementos de la matriz

$$(6.4.1) \quad \hat{\Sigma} = \frac{1}{n-k} R_0$$

son estimadores insesgados de los elementos de Σ . La matriz R_0 ha sido obtenida en §6.2.

La matriz Σ_E depende, por una parte, de los parámetros desconocidos $\beta_{i1}, \dots, \beta_{ik}, \bar{\beta}_i$ ($i=1, \dots, p$), y por otra de las probabilidades, en la práctica también desconocidas, p_1, \dots, p_k .

Ya hemos visto que \bar{y}_{it} es el estimador lineal insesgado de varianza mínima de β_{it} . Es bien conocido que la misma propiedad tiene la frecuencia relativa n_t/n como estimación de la probabilidad p_t ($t=1, \dots, p$). Finalmente, para estimar

$$\bar{\beta}_i = \sum_{t=1}^k p_t \beta_{it}$$

podremos utilizar el estimador

$$\sum_{t=1}^k \frac{n_t}{n} \bar{y}_{it} = \bar{y}_{i..} = \frac{1}{n} \sum_t \sum_h y_{ith}$$

Con todo esto, la matriz $\hat{\Sigma}_E$, cuyos elementos son

$$(6.4.2) \quad \hat{\sigma}_{Eij} = \sum_{t=1}^k \frac{n_t}{n} (\bar{y}_{it} - \bar{y}_{i..})(\bar{y}_{jt} - \bar{y}_{j..})$$

es una buena estimación de Σ_E .

6.5. EJES CANONICOS

Pasemos a diferenciar los individuos medios. En principio, parece que bastaría un análisis de componentes principales sobre la matriz Σ_E , perodado que la métrica de matriz Σ también influye en las variables, deberemos encontrar unas variables que expliquen al máximo la variabilidad de Σ_E , al tiempo que minimicen la influencia de Σ .

Sea $nv = \min(p, k-1) = \text{rang}(\Sigma_E)$. Llamaremos variables canónicas a las v.a. V_1, \dots, V_{nv} de E tales que:

- 1) Son simultáneamente ortogonales respecto a Σ y Σ_E

$$V_i \cdot V_j = 0 \quad V_i \cdot V_j = 0 \quad i, j = 1, \dots, nv \\ i \neq j$$

- 2) Maximizar los cocientes de los módulos al cuadrado

$$\frac{V_1 \circ V_1}{V_1 \cdot V_1} = \lambda_1 = \text{máx.}, \dots, \frac{V_{nv} \circ V_{nv}}{V_{nv} \cdot V_{nv}} = \lambda_{nv} = \text{máx.}$$

Según el teorema fundamental, el problema de determinar las variables canónicas se resuelve obteniendo los vectores propios y valores propios de Σ_E respecto a E

$$(6.5.1) \quad \det(\Sigma_E - \lambda \Sigma) = 0, \quad \Sigma_E V_i = \lambda_i \Sigma V_i \\ i=1, \dots, nv$$

Para determinar el módulo de tales vectores, podemos exponer 2) en la forma equivalente

$$V_1 \circ V_1 = \lambda_1 = \text{máx.}, \dots, V_{nv} \circ V_{nv} = \lambda_{nv} = \text{máx.}$$

$$\|V_1\|_{\Sigma} = \dots = \|V_{nv}\|_{\Sigma} = 1$$

es decir, respecto a Σ , el sistema de vectores canónicos es ortonormal.

Las d primeras v.a. canónicas serán las direcciones vectoriales que reflejarán la máxima covariabilidad entre las poblaciones. Llamaremos espacio vectorial canónico EC_d , de dimensión d , al subespacio de E generado por estas d primeras v.a. canónicas,

$$EC_d = \langle V_1, \dots, V_d \rangle$$

Consideremos ahora el subespacio F_{p-d}^* de E^*

$$F_{p-d}^* = \{ \omega^* \in E^*, \omega^*(V) = 0, \forall V \in EC_d \}$$

Recordando que en E^* hay una métrica, de matriz asociada Σ^{-1} en la base dual (§2.2), llamaremos espacio dual canónico al espacio $EC_d^* = (F_{p-d}^*)^{\perp}$, ortocomplementa- de F_{p-d}^* en E^* . Se tiene:

$$E^* = EC_d^* \oplus F_{p-d}^*$$

A los elementos de la base de EC_d^* ,

$$EC_d^* = \langle V_1^*, \dots, V_d^* \rangle, \quad \|V_i^*\|_{L^{-1}} = 1$$

tales que

$$EC_1^* = \langle V_1^* \rangle \quad EC_2^* = \langle V_1^*, V_2^* \rangle \quad \dots \quad EC_d^*$$

les llamaremos ejes canónicos.

La inyección,

$$(6.5.2) \quad EC_d \xrightarrow{i} E$$

nos definirá una proyección

$$\pi: E^* \longrightarrow EC_d^*$$

$$(6.5.3) \quad \pi(\omega^*) = \omega_1^* \quad \text{si} \quad \omega^* = \omega_1^* + \omega_2^* \\ \omega_1^* \in EC_d^*, \quad \omega_2^* \in F_{p-d}^*$$

que llamaremos proyección canónica.

Sea V la matriz cuyos vectores columna son las componentes en la base $\{Y_i\}$ de las d primeras variables canónicas. La imagen de ω^* , con componentes $W = (w_1, \dots, w_p)^t$ en la base dual $\{Y_i^*\}$, por la proyección canónica, será ω_1^* , y cuyas componentes $\bar{W} = (\bar{w}_1, \dots, \bar{w}_d)$ en los ejes canónicos se obtendrán de

$$(6.5.4) \quad \bar{W} = V'W$$

6.6. REPRESENTACION CANONICA

Aplicando la proyección canónica (6.5.3) a cada uno de los individuos medios m_1^*, \dots, m_k^* , obtendremos k puntos en el espacio dual canónico EC_d^*

$$m_{c1}^* = \pi(m_1^*), \dots, m_{ck}^* = \pi(m_k^*)$$

que se pueden representar tomando como origen

$$\bar{m}_0^* = \eta(\bar{m}^*) \quad \text{siendo} \quad \bar{m}^* = \sum_{h=1}^k P_h m_h^*$$

el centroide ponderado de los k individuos medios.

Para la representación gráfica se tomará, naturalmente, $d=1,2,3$ y en ella quedará reflejada la parte más importante de las diferencias entre los individuos medios.

Supongamos ahora que la distribución conjunta de las v.a. (Y_1, \dots, Y_p) es normal multivariante,

$$N((\beta_{1j}, \dots, \beta_{pj})', \Sigma) \quad \text{en } H_j \quad (j=1, \dots, k)$$

Consideremos el suceso $(S_j, H_j) \in \mathcal{B}^p \cdot \mathcal{A}_H$, siendo

$$S_j = \{ i^* \in E^*, \|i^* - m_j^*\| \leq R_\alpha \}$$

La distancia $\|i^* - m_j^*\|$ viene dada por la métrica en E de matriz asociada L^{-1} (§ 2.2). S_j es un elipsoide en E^* .

A este suceso le corresponde, por la isometría del teorema 2.3.1, el suceso $\bar{B}_j \subset H_j / \mathcal{I}N$, siendo

$$\bar{P}_{H_j}(\bar{B}_j) = P_{F_j}(S_j) \quad j=1, \dots, k$$

Si esta probabilidad es elevada, \bar{B}_j representa la "mayor parte" de la población H_j , y por la aplicación δ , su representación multivariante es $S_j \subset E^*$ (§ 2.3, § 2.5). Ocupémonos ahora de la representación canónica de S_j .

Teorema 6.6.1

Sea $\dim EC_d = \dim EC_d^* = d$. La probabilidad del suceso

$$S_j = \{ i^* \in E^*, \|i^* - m_j^*\| \leq R_\alpha \} \quad j=1, \dots, k$$

es $P(S_j) = 1 - \alpha$, siendo α y R_α tales que $P(\chi_p^2 > R_\alpha^2) = \alpha$, y χ_p^2 una v.a. con distribución ji-cuadrado, con p g. de l.

La imagen de S_j por la proyección canónica,

$$\pi(S_j) = \{ i_c^* \in EC_d^*, \|i_c^* - m_{cj}^*\| \leq R_\alpha \} \quad j=1, \dots, k$$

es una esfera en EC_d^* , de centro m_{cj}^* y radio R_α .

Demostración:

La aplicación:

$$G: E^* \rightarrow R$$

$$G(i^*) = \|i^* - m_j^*\|^2 \quad i^* \in E^*$$

define una v.a. sobre E^* , que sigue la distribución ji-cuadrado, con p grados de libertad. Luego,

$$P(S_j) = P(G \leq R_\alpha^2) = 1 - \alpha$$

siendo $P(\chi_p^2 > R_\alpha^2) = \alpha$

(χ_p^2 , ji-cuadrado con p g. de l.)

La imagen de S_j por la proyección canónica π , es una esfera en EC_d^* , porque estará referido a la base canónica que es ortonormal.

c. q. d.

Utilizando las estimaciones $\hat{m}_1^*, \dots, \hat{m}_k^*$ de los individuos medios, y la estimación $\hat{\Gamma}$ de la matriz Γ , el teorema anterior nos da una forma sencilla, pero aproximada, de representar los individuos de cada una de las poblaciones, mediante esferas de radio común R_α , en el sentido de que un individuo de H_j , pertenece a la esfera $\pi(S_j) \subset EC_d^*$, con probabilidad $(1 - \alpha)$.

Seguidamente, determinaremos unas regiones confidenciales, esta vez exactas, para los k individuos medios.

Necesitaremos el siguiente resultado:

Teorema 6.6.2

Sea γ un vector aleatorio de dimensión p , con distribución $N(0, \Sigma)$, estocásticamente independiente de nS , en donde S es una matriz aleatoria, con la misma distribución que

$$\sum_{\alpha=1}^n Z_{\alpha} Z_{\alpha}'$$

siendo los Z_{α} también p vectores aleatorios estocásticamente independientes, con distribución $N(0, \Sigma)$. Dada entonces la v.a.:

$$T^2 = \gamma' S^{-1} \gamma$$

la distribución de

$$\frac{T^2}{n} \frac{n-p+1}{p}$$

sigue una F de Fisher con p y $(n-p+1)$ grados de libertad

La demostración de este teorema, puede verse en ANDERSON (1958, pág. 106).

Teorema 6.6.3

El conjunto de EC_d^* (de dimensión d), referido a los ejes canónicos,

$$R(\hat{m}_{cj}^*) = \{i_c^* \mid \|i_c^* - \hat{m}_{cj}^*\| \leq \frac{R_{\alpha}}{\sqrt{n_j}}\}$$

es una esfera de radio $R_{\alpha} / \sqrt{n_j}$ y centro \hat{m}_{cj}^* , que define una región confidencial para m_{cj}^* , con probabilidad $(1-\alpha)$

$$P [m_{cj}^* \in R(\hat{m}_{cj}^*)] = 1-\alpha$$

siendo R_{α} tal que

$$R_{\alpha}^2 = F_{\alpha} \frac{(n-k)p}{(n-k-p+1)}$$

y $P(F > F_{\alpha}) = \alpha$, en donde F es una v.a. que sigue una distribución de Fisher con p y $(n-k-p+1)$ g. de l.

Demostación:

De una muestra de tamaño $\Delta = (n_1, \dots, n_k)$, indiquemos por:

$$y_{ih} = (Y_{1ih}, \dots, Y_{pih})'$$

el vector aleatorio de los p valores muestrales, muestra h , población N_i , y por:

$$\bar{y}_i = (\bar{Y}_{1i}, \dots, \bar{Y}_{pi})'$$

el vector aleatorio de medias muestrales en la población N_i . Entonces:

$$(n-k) \hat{\epsilon} = \sum_{i=1}^k \sum_{h=1}^{n_i} (y_{ih} - \bar{y}_i)(y_{ih} - \bar{y}_i)'$$

y se verifica la identidad:

$$\sum_{i=1}^k \sum_{h=1}^{n_i} y_{ih} y_{ih}' = (n-k) (y_1 y_1' + \dots + y_k y_k' + \hat{\epsilon})$$

Supongamos ahora que la esperanza de cada una de las v.a. (Y_1, \dots, Y_p) es cero. Esto no altera los elementos de la matriz Σ , que son formas cuadráticas de rango $(n-k)$. Asimismo, el rango de cada $y_i y_i'$ es uno. Puesto que:

$$n_1 + \dots + n_k = (n-k) + (1 + \dots + 1)$$

por el teorema de Cochran, generalizado al análisis multivariante, (v. ANDERSON, 1958, pág. 165), $(n-k)\hat{\epsilon}$ es independiente de cada $y_i y_i'$, es decir, de y_i , y sigue la distribución

$$\sum_{\alpha=1}^{n-k} Z_{\alpha} \cdot Z_{\alpha}'$$

en donde los Z_{α} son p vectores aleatorios independientes, y cada uno de ellos con distribución $N(0, \Sigma)$.

Entonces, el vector aleatorio