

Forma Canónica del Modelo Ω

Dada una base ortonormal de $\mathcal{V}_r = \mathcal{V}_{\mathbf{X}}$, digamos $\{\boldsymbol{\alpha}_1, \dots, \boldsymbol{\alpha}_r\}$, sabemos que podemos extenderla a una base ortonormal de \mathfrak{R}^n : $\{\boldsymbol{\alpha}_1, \dots, \boldsymbol{\alpha}_r, \boldsymbol{\alpha}_{r+1}, \dots, \boldsymbol{\alpha}_n\}$.

Por lo tanto,

$$\mathbf{y} \in \mathfrak{R}^n : \mathbf{y} = \sum_{j=1}^n z_j \boldsymbol{\alpha}_j$$

y tenemos que

$$\boldsymbol{\alpha}'_i \mathbf{y} = \sum_{j=1}^n z_j \boldsymbol{\alpha}'_i \boldsymbol{\alpha}_j = z_i \boldsymbol{\alpha}'_i \boldsymbol{\alpha}_i = z_i \quad \forall i = 1, \dots, n$$

Luego, si definimos a \mathbf{T} como la matriz que tiene filas $\boldsymbol{\alpha}'_i$, entonces

$$\mathbf{z} = \mathbf{T}\mathbf{y}$$

Observemos que

$$E(z_i) = \begin{cases} \boldsymbol{\alpha}'_i \boldsymbol{\eta} = \xi_i & \text{si } 1 \leq i \leq r \\ 0 & \text{si } r+1 \leq i \leq n \end{cases}$$

$$\Sigma_{\mathbf{z}} = \mathbf{T}\Sigma_{\mathbf{y}}\mathbf{T}' = \sigma^2 \mathbf{I}$$

Por lo tanto, ahora podemos reescribir a Ω como

$\Omega :$

$$E(z_i) = \begin{cases} \xi_i & \text{si } 1 \leq i \leq r \\ 0 & \text{si } r+1 \leq i \leq n \end{cases}$$

$$\Sigma_z = \sigma^2 \mathbf{I}$$

donde ξ y σ^2 son parámetros desconocidos.

En términos de esta forma caónica es sencillo demostrar que

$$s^2 = \frac{\|\mathbf{Y} - \widehat{\mathbf{Y}}\|^2}{n-r} = \frac{\|\mathbf{Y} - \widehat{\boldsymbol{\eta}}\|^2}{n-r}$$

es un estimador insesgado de σ^2 . Sólo habíamos demostrado hasta ahora el caso de rango completo.

Distribución Normal Multivariada

Definición 1: Se dice que un vector \mathbf{X} , k -dimensional tiene distribución normal multivariada $N_k(\boldsymbol{\mu}, \mathbf{Q})$ donde $\boldsymbol{\mu}$ es un vector k -dimensional, \mathbf{Q} una matriz de $k \times k$ definida positiva, si su densidad es de la forma

$$f_{\mathbf{X}}(\mathbf{x}) = \frac{1}{(\sqrt{2\pi})^k |\mathbf{Q}|^{1/2}} e^{-\frac{(\mathbf{x}-\boldsymbol{\mu})' \mathbf{Q}^{-1} (\mathbf{x}-\boldsymbol{\mu})}{2}}$$

donde $|\mathbf{Q}|$ indica determinante de \mathbf{Q} .

Por ejemplo, si X_i son k v.a. independientes tales que $X_i \sim N(\mu_i, \sigma_i^2)$, entonces el vector $\mathbf{X}' = (X_1, \dots, X_k)$ tiene densidad

$$f_{\mathbf{X}}(\mathbf{x}) = \frac{1}{(\sqrt{2\pi})^k \prod_{j=1}^k (\sigma_j^2)^{1/2}} e^{-1/2 \{ \sum_{i=1}^k (x_i - \mu_i)^2 / \sigma_i^2 \}}$$

Luego, resulta que \mathbf{X} es $N_k(\boldsymbol{\mu}, \mathbf{Q})$ donde $\boldsymbol{\mu}' = (\mu_1, \dots, \mu_k)$ y

$$\mathbf{Q} = \text{diag}(\sigma_1^2, \dots, \sigma_k^2) = \begin{pmatrix} \sigma_1^2 & & \\ & \dots & \\ & & \sigma_k^2 \end{pmatrix}$$

Más aún, en el caso en que las k v.a. X_i son todas $N(0, 1)$, \mathbf{X} es $N(\mathbf{0}_k, \mathbf{I}_k)$ donde $\mathbf{0}'_k = (\mathbf{0}, \dots, \mathbf{0}) \in \mathfrak{R}^k$ y \mathbf{I}_k es la matriz identidad de $k \times k$.

Recordemos el enunciado del **Teorema de Cambio de Variable**:

Sean \mathbf{x} es un vector aleatorio con densidad f y $\mathbf{y} = g(\mathbf{x})$, tal que $g^{-1}(\mathbf{y}) = \mathbf{x}$.
Supongamos que en un abierto \mathcal{G} existen las derivadas parciales $\frac{\partial x_i}{\partial y_j}$ y sea

$$J = \det \left\{ \frac{\partial x_i}{\partial y_j} \right\}, \text{ entonces}$$

$$f_{\mathbf{Y}}(\mathbf{y}) = f_{\mathbf{X}}(g^{-1}(\mathbf{y}))|J|$$

Teorema N1: Si \mathbf{X} es un vector aleatorio k -dimensional con distribución $N_k(\boldsymbol{\mu}, \mathbf{Q})$, \mathbf{A} es una matriz no singular de $k \times k$ y \mathbf{b} un vector k -dimensional, entonces

$$\mathbf{Y} = \mathbf{AX} + \mathbf{b} \quad \text{es} \quad N_k(\mathbf{A}\boldsymbol{\mu} + \mathbf{b}, \mathbf{AQA}')$$

Teorema N2:

i) Un vector aleatorio k -dimensional \mathbf{X} es $N_k(\boldsymbol{\mu}, \mathbf{Q})$ si y sólo si $\mathbf{X} = \mathbf{B}\mathbf{Y} + \boldsymbol{\mu}$, donde \mathbf{Y} es $N_k(\mathbf{0}_k, \mathbf{I}_k)$ y \mathbf{B} es una matriz de $k \times k$ no singular tal que $\mathbf{B}\mathbf{B}' = \mathbf{Q}$.

ii) Si \mathbf{X} es $N_k(\boldsymbol{\mu}, \mathbf{Q})$ entonces

$$E(\mathbf{X}) = \boldsymbol{\mu} \quad \text{y} \quad \Sigma_{\mathbf{X}} = \mathbf{Q}$$

Teorema N3: Sea \mathbf{X} un vector aleatorio k -dimensional $N_k(\boldsymbol{\mu}, \mathbf{Q})$ y \mathbf{A} una matriz de $h \times k$ con rango h , luego si $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{b}$ entonces

$$\mathbf{Y} \sim N_h(\mathbf{A}\boldsymbol{\mu} + \mathbf{b}, \mathbf{A}\mathbf{Q}\mathbf{A}')$$

Teorema N4: Sea $\mathbf{X}' = (X_1, \dots, X_k)$ un vector k -dimensional con distribución normal multivariada, luego la distribución marginal de cualquier subconjunto de componentes tiene distribución normal multivariada. En particular cada componente es normal.

Demostración: Sea $\mathbf{X}^* = (X_{k_1}, \dots, X_{k_h})$, $k_1 < k_2 < \dots < k_h$, luego se tiene que $\mathbf{X}^* = A\mathbf{X}$, donde A es la matriz de $h \times k$ dada por:

$$a_{ij} = \begin{cases} 1 & \text{si } j = k_i \\ 0 & \text{si } j \neq k_i \end{cases}$$

$$1 \leq i \leq h, 1 \leq j \leq k.$$

Es fácil ver que A es una matriz de rango h .

Teorema N5: Si \mathbf{X} es un vector k -dimensional con distribución $N_k(\boldsymbol{\mu}, \mathbf{Q})$, luego

$$(\mathbf{X} - \boldsymbol{\mu})' \mathbf{Q}^{-1} (\mathbf{X} - \boldsymbol{\mu}) \sim \chi_k^2$$

.

Demostración: Por lo ya visto, resulta que $\mathbf{X} = \mathbf{B}\mathbf{Y} + \boldsymbol{\mu}$ donde \mathbf{Y} es $N(\mathbf{0}_k, \mathbf{I}_k)$

$$\mathbf{Y} = \mathbf{B}^{-1}(\mathbf{X} - \boldsymbol{\mu})$$

y además

$$\mathbf{B}\mathbf{B}' = \mathbf{Q}$$

Luego

$$\mathbf{Y}\mathbf{Y}' = (\mathbf{X} - \boldsymbol{\mu})' \mathbf{B}'^{-1} \mathbf{B}^{-1} (\mathbf{X} - \boldsymbol{\mu}) = (\mathbf{X} - \boldsymbol{\mu})' \mathbf{Q}^{-1} (\mathbf{X} - \boldsymbol{\mu})$$

El teorema resulta del hecho que

$$\mathbf{Y}'\mathbf{Y} = \sum_{i=1}^k Y_i^2$$

tiene distribución χ_k^2 , ya que las Y_i son variables aleatorias independientes con distribución $N(0, 1)$.

Teorema N6: Si \mathbf{X} es un vector k -dimensional con distribución $N_k(\boldsymbol{\mu}, \sigma^2 \mathbf{I}_k)$ y \mathbf{P} una matriz simétrica e idempotente de rango r , entonces

$$\frac{(\mathbf{X} - \boldsymbol{\mu})' \mathbf{P} (\mathbf{X} - \boldsymbol{\mu})}{\sigma^2} \sim \chi_r^2$$

Tests y Regiones de Confianza

Hasta ahora hemos trabajado sólo con las hipótesis Ω . Sin embargo para deducir tests y regiones de confianza con nivel exacto será necesario que hagamos un supuesto adicional: **normalidad conjunta de los errores**

Supondremos que las y_i 's se distribuyen conjuntamente según una normal multivariada.

Podremos deducir:

- intervalos de confianza de nivel exacto para funciones paramétricas estimables
- tests de nivel exacto para hipótesis que involucran a los parámetros
- conjuntos o regiones de confianza para la estimación simultánea de más de una función paramétrica estimable.

Nuestro nuevo modelo será:

$$\Omega : \mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}) \quad \text{rg}(\mathbf{X}) = r \quad \boldsymbol{\beta} \in \mathbb{R}^p$$

Observemos que en este caso suponer que $\Sigma_{\mathbf{Y}} = \sigma^2\mathbf{I}$ es equivalente a asumir que las y_i , $1 \leq i \leq n$, son independientes.

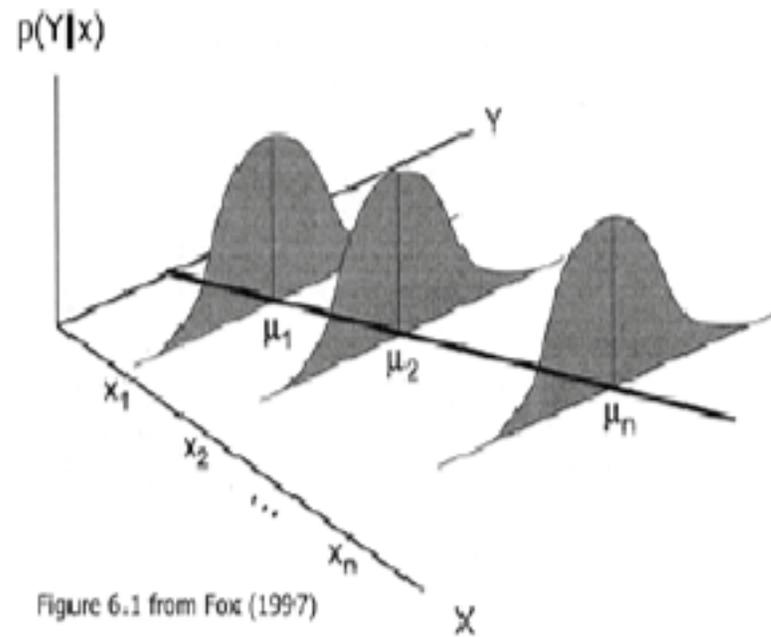


Figure 6.1 from Fox (1997)

Bajo estas condiciones se obtiene el siguiente resultado:

Teorema: Supongamos que se tiene el modelo

$$\Omega : \mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}) \quad \text{rg}(\mathbf{X}) = p \quad \boldsymbol{\beta} \in \mathbb{R}^p .$$

Luego, $\widehat{\boldsymbol{\beta}}$ y s^2 son funciones de estadísticos suficientes y completos y por lo tanto, $\widehat{\boldsymbol{\beta}}$ y s^2 son estimadores IMVU de $\boldsymbol{\beta}$ y σ^2 , respectivamente.

Si nuestro modelo es

$$E(\mathbf{Y}) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

podríamos tener interés en testear hipótesis como las que siguen:

$$H_0 : \beta_j = 0 \quad \text{vs.} \quad H_1 : \beta_j \neq 0$$

$$H_0 : \beta_1 - \beta_2 = 0 \quad \text{vs.} \quad H_1 : \beta_1 - \beta_2 \neq 0$$

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0 \quad \text{vs.} \quad H_1 : \text{existe } j : \beta_j \neq 0$$

Todas estas hipótesis son de la forma $\mathbf{c}'\boldsymbol{\beta} = 0$ o $\mathbf{C}\boldsymbol{\beta} = \mathbf{0}$.

Supongamos que tenemos q funciones estimables $\psi_1, \psi_2, \dots, \psi_q$ donde:

$$\psi_i = \sum_{j=1}^p c_{ij}\beta_j \quad 1 \leq i \leq q$$

Por ser estimables, por el Teorema de Gauss–Markov tenemos que

$$\widehat{\psi}_i = \sum_{j=1}^n a_{ij}^* y_j \quad 1 \leq i \leq q,$$

donde $\mathbf{a}_i^* \in \mathcal{V}_r \subset \mathfrak{R}^n$; de manera que

$$\begin{aligned} \Psi &= \mathbf{C}\beta & \mathbf{C} &\in \mathfrak{R}^{q \times p} \\ \widehat{\Psi} &= \mathbf{A}^* \mathbf{Y} & \mathbf{A}^* &\in \mathfrak{R}^{q \times n} \end{aligned}$$

Más aún, sabemos que

$$\begin{aligned} \widehat{\Psi} &= \mathbf{C}\widehat{\beta} \\ \Sigma_{\widehat{\Psi}} &= \sigma^2 \mathbf{A}^* \mathbf{A}^{*'} \end{aligned}$$

Estimamos a σ^2 por

$$s^2 = \frac{\|\mathbf{Y} - \widehat{\mathbf{Y}}\|^2}{n - r}$$

Bajo estas nuevas hipótesis obtenemos el siguiente resultado:

Teorema: Supongamos que se cumple Ω , es decir $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I})$, $\text{rg}(\mathbf{X}) = r$, $\boldsymbol{\beta} \in \mathfrak{R}^p$ y que además que $\psi_1, \psi_2, \dots, \psi_q$ son q funciones estimables l.i., de manera que $\text{rg}(\mathbf{C}) = q$. Entonces,

- i) $\widehat{\Psi} \sim N_q(\Psi, \Sigma_{\widehat{\Psi}})$ (o lo que es igual $N_q(\Psi, \sigma^2\mathbf{A}^*\mathbf{A}^')$)
- ii) $\widehat{\Psi}$ y $\frac{s^2(n-r)}{\sigma^2}$ son independientes
- iii) $\frac{(n-r)s^2}{\sigma^2} \sim \chi_{n-r}^2$

En el caso de rango completo, es decir cuando $r = p$, obtenemos el siguiente resultado:

Teorema: Supongamos que se cumple Ω , es decir $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I})$, $\text{rg}(\mathbf{X}) = p$, $\boldsymbol{\beta} \in \mathbb{R}^p$. Entonces,

$$\text{i) } \widehat{\boldsymbol{\beta}} \sim N_p(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$$

$$\text{ii) } \frac{(\widehat{\boldsymbol{\beta}} - \boldsymbol{\beta})'(\mathbf{X}'\mathbf{X})(\widehat{\boldsymbol{\beta}} - \boldsymbol{\beta})}{\sigma^2} \sim \chi_p^2$$

$$\text{iii) } \widehat{\boldsymbol{\beta}} \text{ y } \frac{(n-p)s^2}{\sigma^2} \text{ son independientes}$$

$$\text{iv) } \frac{(n-p)s^2}{\sigma^2} \sim \chi_{n-p}^2$$

Estos resultados nos permiten deducir intervalos de confianza o tests para cada uno de los coeficientes del modelo lineal: