


## 4b - $H_0: A\beta = c$





## Resultados. Álgebra lineal y distribuciones<sup>1</sup>

### Proposición

Sea  $x_{n \times 1}$  un vector aleatorio con media  $\mathbb{E}(x) = \mu_{n \times 1}$ , y matriz de covarianzas  $\text{var}(x) = \Sigma_{n \times n}$ . Sean  $A_{m \times n}$  y  $B_{n \times n} > 0$  y  $C_{s \times r}$  matrices de constantes y  $y_{r \times 1}$  un vector aleatorio. Entonces,

- 1  $\mathbb{E}[Ax] = A\mathbb{E}[x] = A\mu.$
- 2  $\text{var}(Ax) = A\text{var}(x)A' = A\Sigma A'.$
- 3  $\text{cov}(Ax, Cy) = A\text{cov}(x, y)C'.$
- 4  $\mathbb{E}[x'Bx] = \text{tr}[B\Sigma] + \mu'B\mu.$

### Proposición

Sea  $x \sim N_n(0, \Sigma)$ . Entonces,  $x'\Sigma^{-1}x \sim \chi_n^2$ .

### Proposición

Sea  $H$  una matriz  $n \times n$ , simétrica e idempotente, entonces  $H$  es una matriz de proyección sobre  $\mathcal{L}(H)$ , subespacio generado por las columnas de  $H$ . Luego,  $(I - H)$  es la matriz de proyección sobre el subespacio ortogonal a  $\mathcal{L}(H)$ .

<sup>1</sup>Schott (1997)

## Resultados (cont.)

## Proposición

Sean  $X_{n \times q}$  con  $\text{rango}(X) = q$ , y las matrices de proyección  $H = X(X'X)^{-1}X'$  y  $M = (I - H)$ . Entonces,  $\text{rango}(H) = q$  y  $\text{rango}(M) = n - q$ .

## Proposición

Sea  $L$  una matriz definida positiva. Entonces, para todo vector  $b$  se tiene que

$$\sup_{h \neq 0} \left\{ \frac{(h'b)^2}{h' L h} \right\} = b' L^{-1} b$$

## Modelo de Regresión Lineal Múltiple <sup>2</sup>

Considere el modelo de regresión lineal

$$y_i = \beta_0 + \beta_1 x_{i1} + \cdots + \beta_p x_{ip} + \epsilon_i, \quad i = 1, \dots, n$$

### Modelo de Regresión Lineal Múltiple

$$y = X\beta + \epsilon \quad (1)$$

con  $y_{n \times 1}$ ,  $\epsilon_{n \times 1}$ ,  $\beta_{q \times 1}$ , y  $X_{n \times q}$ , donde  $q = 1 + p$ .

La **suma de cuadrados**  $SC(\beta) = \sum_{i=1}^n (y_i - \beta' x_i)^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \cdots - \beta_p x_{ip})^2$  queda matricialmente

### Suma Cuadrados

$$SC(\beta) = \|y - X\beta\|^2 = (y - X\beta)'(y - X\beta)$$

Si el criterio de estimación es **mínimos cuadrados**,  $\frac{\partial SC(\beta)}{\partial \beta} = 2X'X\beta - 2X'y = 0$ ,

### Ecuaciones Normales de Mínimos Cuadrados

$$X'X\beta = X'y \quad (2)$$

<sup>2</sup>Trabajo apoyado principalmente en Seber (1977) y Seber and Lee (2003):

## Estimadores de Mínimos Cuadrados (EMC)

$$\hat{\beta} = (X'X)^{-1}X'y \quad (3)$$

Se define la *respuesta ajustada* como  $\hat{y} = X\hat{\beta}$  y su correspondiente vector de *residuales* por  $\hat{\epsilon} = y - \hat{y}$ .

La *suma de cuadrados de los residuales* ( $SC_{Res}$ ), también llamada *suma de cuadrados de los errores*:  $SC(\hat{\beta}) = \sum_{i=1}^n (y_i - \hat{y}_i)^2$ .

## Suma de Cuadrado de los Residuales ( $SC_{Res}$ )

$$SC_{Res} = \|y - X\hat{\beta}\|^2 = y'y - \hat{\beta}'X'y$$

utilizando las ecuaciones normales (2). Note

$$\begin{aligned} \hat{y} &= X\hat{\beta} = X(X'X)^{-1}X'y = Hy \\ \hat{\epsilon} &= y - X(X'X)^{-1}X'y = (I - H)y = My \end{aligned} \quad (4)$$

donde  $H$  y  $M$  son matrices *simétricas e idempotentes*<sup>3</sup>. Luego, la suma de cuadrados de los errores se puede expresar también en términos de  $M$  como

$$SC_{Res} = \|\hat{\epsilon}\|^2 = \hat{\epsilon}'\hat{\epsilon} = y'M^2y = \epsilon'M\epsilon$$

$y = X\beta + \epsilon$  y  $M$  es la matriz de proyección ortogonal al espacio generado por las columnas de  $X$ .

<sup>3</sup>Para algunas propiedades de las matrices de proyección  $H$  y  $M$  refiérase a (Hoaglin and Welsch 1978).

## Proposición

Considere el modelo de regresión lineal

$$y = X\beta + \epsilon$$

con vector de medias y matriz de covarianzas

$$\mathbb{E}[\epsilon] = 0 \quad \text{y} \quad \text{cov}(\epsilon) = \sigma^2 I_n$$

Entonces se cumplen los siguientes resultados:

- a  $\mathbb{E}[y] = X\beta$ . Es decir, el modelo es *correcto*.
- b  $\text{cov}(y) = \sigma^2 I_n$ .
- c  $\text{cov}(\hat{\epsilon}) = \sigma^2 M$ .
- d  $\mathbb{E}[\hat{\beta}] = \beta$ . El EMC es *insesgado*.
- e  $\text{cov}(\hat{\beta}) = \sigma^2 (X'X)^{-1} = \sigma^2 C$ .

## Proposición (cont.)

- f Si  $\text{tr}(X'X)^{-1} \rightarrow 0$ , conforme  $n \nearrow \infty$ , entonces  $\hat{\beta}$  es además un estimador consistente de  $\beta$ .
- g  $S(\hat{\beta}) = \sum_i m_{ii}\epsilon_i^2 + \sum_{i \neq j} m_{ij}\epsilon_i\epsilon_j$
- h  $\mathbb{E}[S(\hat{\beta})] = (n - q)\sigma^2$ .
- i  $\mathbb{E}[s^2] = \sigma^2$ .
- j  $s^2$  es un estimador insesgado y consistente de  $\sigma^2$ <sup>a</sup>.
- k Un estimador insesgado y consistente de  $\text{cov}(\hat{\beta})$  es  $s^2(X'X)^{-1} = s^2C$ .
- l Un estimador de la matriz de correlación del parámetro  $\hat{\beta}$ ,

$$R = \widehat{\text{corr}}(\hat{\beta}) = \left[ \frac{C_{ij}}{\sqrt{C_{ii}C_{jj}}} \right]$$

<sup>a</sup>Refiérase a (Sen and Srivastava 1990) Sec. 2A.2.



## Teorema de Gauss-Markov<sup>4</sup>

### Función estimable

La función paramétrica  $a'\beta$  es una *función estimable* si tiene un estimador lineal insesgado, por ejemplo,  $c'y$ .

### Teorema Gauss-Markov – caso escalar

Considere el modelo de regresión lineal  $y = X\beta + \epsilon$  y el EMC del vector de coeficientes  $\hat{\beta} = (X'X)^{-1}X'y$ . Bajo la condiciones usuales de la regresión (7), el estimador de mínimos cuadrados  $\hat{\theta} = \ell'\hat{\beta}$  de la función estimable  $\theta = \ell'\beta$ , tiene mínima varianza entre todos los estimadores lineales insesgados de  $\theta$ .

### Teorema Gauss-Markov – caso vectorial

Bajo la condiciones usuales de la regresión lineal, el estimador  $L'\hat{\beta}$  de mínimos cuadrados de la función estimable  $\Theta = L'\beta$  es de varianza mínima entre todos los estimadores lineales insesgados. Esto es, la matriz  $[\text{cov}(Cy) - \text{cov}(L'\hat{\beta})]$  es semidefinida positiva. Luego, es BLUE.

<sup>4</sup>Sen and Srivastava (1990) Sec. 2.9.

## Distribuciones

## Proposición

Sea  $y \sim N_n(X\beta, \sigma^2 I)$ , con  $X_{n \times q}$ ,  $\text{rango}(X) = q$ , y  $\text{rango}(M) = n - q$ . Entonces,

- 1  $\hat{\beta} \sim N_q(\beta, \sigma^2(X'X)^{-1})$ .
- 2  $\|X(\hat{\beta} - \beta)\|^2 = (\hat{\beta} - \beta)'X'X(\hat{\beta} - \beta) \sim \sigma^2\chi_q^2$ .
- 3  $\hat{\beta}$  es independiente de  $s^2$ .
- 4  $\text{SCE} = (n - q)s^2 \sim \sigma^2\chi_{\nu}^2$ , con  $\nu = n - q$ .

## Mínimos Cuadrados con Restricciones

Considere nuevamente el modelo de regresión lineal múltiple (1)

$$y = X\beta + \epsilon$$

y suponga que se desea ajustar el modelo que satisface la hipótesis

$$H_0 : A\beta = c \quad (6)$$

donde  $A_{r \times q}$  y  $\text{rango}(A) = r (\leq q)$ . Esto es, estimar el valor del parámetro  $\beta$  que satisface las restricciones  $A\beta = c$ .

### Mínimos cuadrados con restricciones

El problema de mínimos cuadrados con restricciones puede plantearse entonces como

$$\text{Minimizar: } SC(\beta) = y'y - 2\beta'X'y + \beta'X'X\beta \quad (7)$$

$$\text{Sujeto a: } A\beta = c$$

## Estimadores

Para resolver el problema de optimización con las restricciones (7), construimos el correspondiente lagrangiano

$$L(\beta, \lambda) = y'y - 2\beta'X'y + \beta'X'X\beta + \lambda'(A\beta - c)$$

Si se deriva el lagrangiano anterior y se iguala a 0,

$$\frac{\partial L}{\partial \beta} = 2(X'X)\beta - 2X'y - A'\lambda = 0; \quad \frac{\partial L}{\partial \lambda} = c - A\beta = 0$$

se da lugar a

$$\hat{\beta}_H = (X'X)^{-1}[X'y + \frac{1}{2}A'\lambda] = \hat{\beta} + \frac{1}{2}(X'X)^{-1}A'\hat{\lambda}$$

$$c = A\hat{\beta}_H = A\hat{\beta} + \frac{1}{2}A(X'X)^{-1}A'\hat{\lambda}$$

donde  $\hat{\beta}$  es el estimador de mínimos cuadrados sin restricciones (3). Luego, eliminando  $\lambda$  en la expresión anterior, se tiene el *estimador de mínimos cuadrados con restricciones*,

### Estimadores Mínimos Cuadrados con Restricciones

$$\hat{\beta}_H = \hat{\beta} + (X'X)^{-1}A' [A(X'X)^{-1}A']^{-1} (c - A\hat{\beta}) \quad (8)$$

solución del problema de minimización de la suma de cuadrados de los residuales cuando los coeficientes satisfacen ciertas condiciones lineales (7).

## Ejemplo

Considere la hipótesis o restricción  $H_0 : \beta_1 = g_1$ . Se sigue de (6) que en este caso  $A = (1, 0, \dots, 0)$ , y  $c = g_1$ . Luego, se sigue de (8) que

$$\hat{\beta}_H = \hat{\beta} + C \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} C_{11}^{-1} (g_1 - \hat{\beta}_1) = \begin{bmatrix} g_1 \\ \hat{\beta}_2 + (g_1 - \hat{\beta}_1) C_{21} / C_{11} \\ \vdots \\ \hat{\beta}_p + (g_1 - \hat{\beta}_1) C_{p1} / C_{11} \end{bmatrix} = \begin{bmatrix} g_1 \\ \hat{\beta}_2 + r_{12} \frac{s_2}{s_1} \delta_1 \\ \vdots \\ \hat{\beta}_p + r_{1p} \frac{s_p}{s_1} \delta_1 \end{bmatrix}$$

donde  $C = (X'X)^{-1} = (C_{ij})$ ,  $\delta_1 = (g_1 - \beta_1)$ ,  $s_i = ee(\hat{\beta}_i)$  es el error estándar de  $\hat{\beta}_i$ , y  $r_{ij} = \text{corr}(\hat{\beta}_i, \hat{\beta}_j)$  es la correlación lineal entre  $\hat{\beta}_i$  y  $\hat{\beta}_j$ , por lo que  $C_{i1} / C_{11} = r_{1i} s_i / s_1$ .

## Distribuciones

Considere nuevamente el modelo de regresión lineal múltiple con el supuesto esférico sobre el error,  $\epsilon \sim N_n(0, \sigma^2 I)$ . Se desea probar la hipótesis

$$H_0 : A\beta = c$$

Sea  $SCE = S(\hat{\beta})$  la suma de cuadrados de los errores sin restricciones y  $SCE_H = S(\hat{\beta}_H)$ , la suma de cuadrados de los errores del problema *con restricciones*

$$SCE_H = \|y - X\hat{\beta}_H\|^2 = (y - X\hat{\beta}_H)'(y - X\hat{\beta}_H)$$

### Proposición

$$\begin{aligned} SCE - SCE_H &= (A\hat{\beta} - c)' [A(X'X)^{-1}A']^{-1} (A\hat{\beta} - c) \geq 0 \\ \mathbb{E}[SCE_H - SCE] &= r\sigma^2 + (A\beta - c)' [A(X'X)^{-1}A']^{-1} (A\beta - c) \end{aligned}$$

## Prueba de Hipótesis

### Teorema

Bajo  $H_0$

$$F = \frac{(\text{SCE}_H - \text{SCE})/r}{\text{SCE}/(n - q)} = \frac{(c - A\hat{\beta})' [A(X'X)^{-1}A']^{-1} (c - A\hat{\beta})}{rs^2} \sim F_{r, n-q}$$

### Teorema

Cuando  $c = 0$ , bajo  $H_0$

$$F = \frac{n - q}{r} \frac{y'(H - P_H)y}{y(I - H)y}$$

donde  $P_H$  es la matriz de proyección (matriz simétrica e idempotente) tal que  $HP_H = P_HH = P_H$ .

## Notas

- 1 Por el teorema de Gauss-Markov,  $A\hat{\beta}$  es el mejor estimador lineal insesgado de  $A\beta$  estimable, que bajo  $H_0$ , sería cercano a  $c$ . Luego,

$$SCE_H - SCE = (A\hat{\beta} - c)' \left[ A(X'X)^{-1}A' \right]^{-1} (A\hat{\beta} - c)$$

es pequeño. En caso contrario, si  $A\hat{\beta}$  no es cercano a  $c$ , la diferencia  $SCE_H - SCE$  tendería a ser grande. Entonces, la “prueba  $F$ ” tiene que ser de una cola. Esto es, la regla de decisión sería: *Rechazar  $H_0$  si  $F > F_{1-\alpha}$* , donde  $F_{1-\alpha}$  es el  $(1 - \alpha)$ -cuantil de la distribución  $F$ .

- 2 Si  $r > 2$  resulta más práctico calcular  $SCE$  y  $SCE_H$  mediante la minimización de  $\epsilon'\epsilon$ , con y sin las restricciones (6).
- 3 Puesto que  $SCE_H$  es única, no importa como se obtiene. Se puede usar  $A\beta = c$  para eliminar algunos de los  $\beta_j$ 's y después minimizar  $||\epsilon||^2$  con respecto a los  $\beta$ 's restantes.
- 4 El procedimiento basado en los 2 incisos anteriores se conoce como *Suma de Cuadrados Extra*, que es la diferencia entre las suma de cuadrados que no alcanza a explicar el modelo reducido, que satisface  $H_0$ , comparado con el modelo completo, sin restricciones.



## Cociente de verosimilitudes

Considere la función de verosimilitud asociada con el modelo de regresión lineal *sin* restricciones

$$L(\beta, \sigma^2 | X, y) = (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta) \right\}$$

La maximización de  $L$  respecto a  $\beta$  y  $\sigma^2$  da lugar a los *estimadores de máxima verosimilitud*, dados por

$$\hat{\beta} = (X'X)^{-1}X'y \quad \text{y} \quad \hat{\sigma}^2 = \frac{\text{SCE}}{n}$$

Entonces el máximo de  $L$  está dado por  $L(\hat{\beta}, \hat{\sigma}^2) = (2\pi\hat{\sigma}^2)^{-n/2} e^{-n/2}$ .

De manera similar, si se satisface  $H_0$ , los correspondientes estimadores de máxima verosimilitud maximizan  $L(\beta, \sigma^2 | X, y)$ , sujeta a las restricciones impuestas por  $H_0$ . Luego

$$\hat{\beta}_H = \hat{\beta} + (X'X)^{-1}A' \left[ A(X'X)^{-1}A' \right]^{-1} (c - A\hat{\beta}) \quad \text{y} \quad \hat{\sigma}_H^2 = \frac{\text{SCE}_H}{n}$$

En este caso, bajo  $H_0$ ,  $L(\hat{\beta}_H, \hat{\sigma}_H^2 | X, y) = (2\pi\hat{\sigma}_H^2)^{-n/2} e^{-n/2}$ .

## Cociente de verosimilitudes (cont.)

Luego, la *razón de verosimilitud* está dada por

$$\Lambda = \frac{L(\hat{\beta}_H, \hat{\sigma}_H^2)}{L(\hat{\beta}, \hat{\sigma}^2)} = \left( \frac{\hat{\sigma}^2}{\hat{\sigma}_H^2} \right)^{n/2}$$

Ahora bien, el *principio de la razón de verosimilitud* indica rechazar  $H_0$  para valores pequeños de  $\Lambda$ , que en este caso es una función monótona decreciente del estadístico  $F$ . A saber,

$$F = \frac{n-p}{q} (\Lambda^{-2/n} - 1)$$

Luego, se rechaza  $H_0 : A\beta = c$ , para valores grandes del estadístico de prueba  $F$ .

Considere el modelo de regresión lineal múltiple

$$y = X\beta + \epsilon$$

### Hipótesis sobre la significancia de la regresión

$$H_0 : \beta = 0, \quad \text{vs.} \quad H_a : \text{Al menos un } \beta_j \neq 0,$$

En el contexto de la prueba general de hipótesis, si  $H_0 : A\beta = c$ , entonces,  $A = I_p$ , la identidad de orden  $p$ , y  $c = 0$ . Luego,  $A\hat{\beta} - c = \hat{\beta}$ . Luego, el estadístico  $F$  toma la forma

$$F = \frac{(X\hat{\beta})'(X\hat{\beta})/p}{\hat{\epsilon}'\hat{\epsilon}/(n-q)} = \frac{\hat{\beta}'X'y/p}{s^2} = \frac{\text{CM}_{\text{Reg}}}{\text{CM}_{\text{Res}}} \sim F_{(p, n-q)} \quad (9)$$

que es como se calcula el estadístico  $F$  a partir de la tabla de ANOVA. El estadístico  $F$  de la expresión anterior (9) es el que reportan los programas estadísticos para verificar la significancia de la regresión.

Considere nuevamente el modelo

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \epsilon$$

conocido en este contexto como *modelo completo* (MC) escrito matricialmente

### Modelo completo (MC)

$$y = X\beta + \epsilon = X_1 B_1 + X_2 B_2 + \epsilon$$

donde,  $B_1$   $q_1 \times 1$ ,  $B_2$   $q_2 \times 1$  y  $X_i$  las matrices  $n \times q_i$  correspondientes para  $i = 1, 2$ .

Ahora bien, se considera la posibilidad de simplificar el modelo al *modelo restringido* (MR)

### Modelo restringido (MR)

$$y = X_1 B_1 + \epsilon$$

Para esto, se contrastan las hipótesis

$$H_0 : B_2 = 0, \quad \text{vs.} \quad H_a : B_2 \neq 0$$

### Estadístico de prueba para suma de cuadrados extra

$$F = \frac{(\text{SC}_{\text{Res}}(\text{MR}) - \text{SC}_{\text{Res}}(\text{MC}))/q_2}{\text{SC}_{\text{Res}}(\text{MC})/(n - q)} \sim F_{q_2, n - q}$$

y se determina su significancia.

## Región de confianza para el vector de parámetros $\beta$

Recuerde que

$$(c - A\hat{\beta})' [A(X'X)^{-1}A']^{-1} (c - A\hat{\beta}) \sim rs^2 F_{r,\nu}$$

donde  $\text{rango}(A) = r$ , y  $\nu = n - q$ . Si se toma  $A = I_q$  y  $c = \beta$ ,

$$\mathbb{P} \left\{ (\hat{\beta} - \beta)' X' X (\hat{\beta} - \beta) \leq rs^2 F(1 - \alpha; r, \nu) \right\} = 1 - \alpha$$

### Región de confianza para $\beta$

$$\mathcal{R}_{1-\alpha} = \left\{ \beta : (\hat{\beta} - \beta)' X' X (\hat{\beta} - \beta) \leq rs^2 F(1 - \alpha; r, \nu) \right\}$$

constituye una región del  $100(1 - \alpha)\%$  confianza para el vector de parámetros  $\beta$ .

## Método de Scheffé

Considere la restricción  $A\beta = c$ . Entonces, por el teorema Gauss-Markov  $A\hat{\beta} = \hat{c}$  es un buen estimador de  $c$  y como se vio

$$\begin{aligned} 1 - \alpha &= \mathbb{P} \left\{ (A\hat{\beta} - c)' \left[ A(X'X)^{-1}A' \right]^{-1} (A\hat{\beta} - c) \leq rs^2 F_{r,\nu} \right\} \\ &= \mathbb{P} \left\{ (\hat{c} - c)' L^{-1} (\hat{c} - c) \leq \xi \right\} \end{aligned}$$

donde  $\hat{c} = A\hat{\beta}$ ,  $L = \left[ A(X'X)^{-1}A' \right]$  y  $\xi = rs^2 F(1 - \alpha; r, \nu)$ . Luego, tomando  $\gamma = \hat{c} - c$  se puede mostrar que

$$\begin{aligned} 1 - \alpha &= \mathbb{P} \left\{ \gamma' L^{-1} \gamma \leq \xi \right\} \\ &= \mathbb{P} \left\{ \sup_{h \neq 0} \left\{ \frac{(h' \gamma)^2}{h' L h} \right\} \leq \xi \right\} \\ &= \mathbb{P} \left\{ \frac{(h' \gamma)^2}{h' L h} \leq \xi, \text{ para todo } h \neq 0 \right\} \\ &= \mathbb{P} \left\{ \frac{(|h'(\hat{c} - c)|)}{s \sqrt{h' L h}} \leq \sqrt{r F(1 - \alpha; r, \nu)} \right\} \end{aligned}$$



## Estimación de respuesta media y nuevas observaciones

### Intervalos de confianza para la respuesta media a nivel $x = x_0$

$$\hat{y}(x_0) \pm t_{(1-\alpha/2, \nu)} s \sqrt{x_0'(X'X)^{-1}x_0}$$

### Intervalos de confianza Bonferroni a nivel $\dot{x}_1, \dots, \dot{x}_m$

$$\hat{y}(\dot{x}_i) \pm t_{(1-\alpha/2m, \nu)} s \sqrt{\dot{x}_i'(X'X)^{-1}\dot{x}_i}$$

### Intervalos de confianza Scheffé a nivel $\dot{x}_i$

$$\hat{y}(\dot{x}_i) \pm (mF(1-\alpha; m, \nu))^{1/2} s \sqrt{\dot{x}_i'(X'X)^{-1}\dot{x}_i}$$

Similarmente pueden construirse regiones simultáneas para predicciones de observaciones nuevas. Utilizando por ejemplo el método de Scheffé, una región de predicción conjunta para niveles de los regresores  $\dot{x}_1, \dots, \dot{x}_\ell$ , está dado por

### Intervalos de confianza conjunto a niveles $\dot{x}_1, \dots, \dot{x}_\ell$

$$\hat{y}(\dot{x}_i) \pm (mF(1-\alpha; \ell, \nu))^{1/2} s \sqrt{1 + \dot{x}_i'(X'X)^{-1}\dot{x}_i}$$





