

Estimación

jueves, 17 de mayo de 2018 10:31

Consideremos los modelos:

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_{p-1} x_{i,p-1} + \varepsilon_i \quad (i=1, \dots, n) \quad (1)$$

o

$$y_i = \beta_0 x_{i0} + \beta_1 x_{i1} + \dots + \beta_{p-1} x_{i,p-1} + \varepsilon_i \quad (i=1, \dots, n)$$

ambos modelos se pueden representar como:

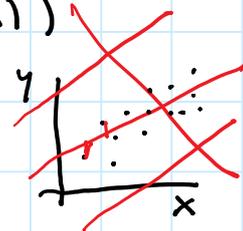
$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} x_{10} & x_{11} & x_{12} & \dots & x_{1,p-1} \\ x_{20} & x_{21} & x_{22} & \dots & x_{2,p-1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{n0} & x_{n1} & x_{n2} & \dots & x_{n,p-1} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_{p-1} \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

matricialmente:

$$Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \varepsilon_{n \times 1} \quad (2)$$

Observemos que ambos modelos en (1) se representan mediante (2) (en el primer caso $x_{i0} = 1$ ($i=1, \dots, n$))

Estimación por mínimos cuadrados



El método consiste en minimizar $\sum_{i=1}^n \varepsilon_i^2$ respecto a β .

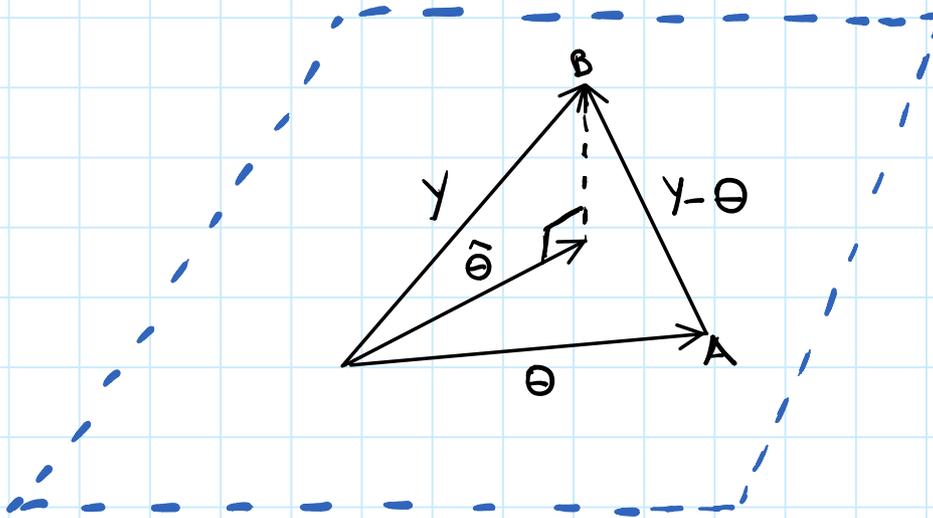
O sea se hallará $\underset{\beta}{\operatorname{arg\,min}} \varepsilon' \varepsilon = \underset{\beta}{\operatorname{arg\,min}} \|Y - X\beta\|^2$

Si consideramos $\Theta = X\beta$ lo anterior es equivalente a

argumen $\|Y - \theta\|^2$ sujeto a $\theta \in \Omega$

con $\Omega = \{y: y = Xx \text{ para todo } x \in \mathbb{R}^p\}$

(Ω es el espacio de las columnas de X)



Si θ varía en Ω , $\|Y - \theta\|^2$ será mínimo en $\theta = \hat{\theta}$ donde $\hat{\theta}$ queda determinado por $(Y - \hat{\theta}) \perp \Omega$

$\hat{\theta}$ cumple que $\hat{\theta} = PY$ donde P es la matriz de proyección ortogonal en Ω (P simétrica e idempotente)

Entonces $Y - \theta = (Y - \hat{\theta}) + (\hat{\theta} - \theta)$

y como $P\theta = \theta$ (ya que $\theta \in \Omega$)

$P' = P$ (P es simétrica)

$P^2 = P$ (P es idempotente)

se tiene que:

$$\begin{aligned}
 (Y - \hat{\theta})(\hat{\theta} - \theta) &= (Y - PY)'(PY - P\theta) = \\
 &= (Y' - \underbrace{Y'P}'_P)P(Y - \theta) = Y'(I_n - P)P(Y - \theta) = 0
 \end{aligned}$$

La última igualdad se debe a que $(Y - \hat{\theta}) \perp (\hat{\theta} - \theta)$
 (Recordar que si $a \perp b \Rightarrow a'b = 0$)

De donde $\|Y - \theta\|^2 = (Y - \theta)'(Y - \theta) =$

$$= ((Y - \hat{\theta}) + (\hat{\theta} - \theta))'((Y - \hat{\theta}) + (\hat{\theta} - \theta)) =$$

$$(Y - \hat{\theta})'(Y - \hat{\theta}) + (Y - \hat{\theta})'(\hat{\theta} - \theta) + (\hat{\theta} - \theta)'(Y - \hat{\theta}) + (\hat{\theta} - \theta)'(\hat{\theta} - \theta)$$

$$= \|Y - \hat{\theta}\|^2 + 2 \underbrace{(Y - \hat{\theta})'(\hat{\theta} - \theta)}_0 + \|\hat{\theta} - \theta\|^2$$

o sea $\|Y - \theta\|^2 = \|Y - \hat{\theta}\|^2 + \|\hat{\theta} - \theta\|^2 \geq \|Y - \hat{\theta}\|^2$

dándose la igualdad si y solo si $\theta = \hat{\theta}$ o sea el mínimo se dará en $\hat{\theta}$

$x \in \Omega \quad \forall v \in \Omega'$

Dado que $Y - \hat{\theta} \perp \Omega$ entonces como $Y - \hat{\theta} \in \text{Ker}(X')$

$$X'(Y - \hat{\theta}) = 0$$

$(Xv)'(Y - \hat{\theta}) = 0$
 $\forall v \in \Omega'$

o $X'\hat{\theta} = X'Y \quad (3)$

De aquí $\hat{\theta}$ está determinado únicamente siendo la única

proyección ortogonal de Y en Ω

Asumamos que las columnas de X son linealmente independientes así pues existe un único vector $\hat{\beta}$ tal que $\hat{\Theta} = X\hat{\beta}$. Entonces a partir de

$$\begin{aligned} X'\hat{\Theta} &= X'Y \\ X'X\hat{\beta} &= X'Y \quad (4) \end{aligned}$$

La ecuación (4) se le llama ecuaciones normales

Como X tiene rango p entonces $X'X$ es definida positiva y no singular

Así existe $(X'X)^{-1}$ y la ecuación (4) tiene solución única dada por

$$\hat{\beta} = (X'X)^{-1} X'Y$$

$\hat{\beta}$ se llamará el estimador de mínimos cuadrados de β

Observación: Si las columnas de X no son linealmente independientes no existe un único $\hat{\beta}$ tal que $\hat{\Theta} = X\hat{\beta}$ así pues (4) no tiene una solución única. Aún así una solución está dada por

$$\hat{\beta} = (X'X)^{-} X'Y \quad (5)$$

siendo $(X'X)^-$ alguna inversa generalizada de $(X'X)$

$$\text{Entonces } \hat{\Theta} = X\hat{\beta} = X(X'X)^-X'Y = PY$$

y dado que P es único, se sigue que P no depende de qué inversa generalizada se usa.

Los valores $\hat{Y} = X\hat{\beta}$ se llamarán valores ajustados. (6)

A los valores $e = Y - \hat{Y}$ se les llamarán residuos

$$e = (Y - \hat{Y}) = (Y - X\hat{\beta}) = (I_n - P)Y \quad (7)$$

Vemos que el mínimo valor de $e'e$ se da en $e'e$

$$e'e = (Y - X\hat{\beta})'(Y - X\hat{\beta}) = Y'Y - 2\hat{\beta}'X'Y + \hat{\beta}'X'X\hat{\beta}$$

$$= Y'Y - \hat{\beta}'X'Y + \hat{\beta}' \underbrace{[X'X\hat{\beta} - X'Y]}_{= 0 \text{ por (4)}} = Y'Y - \hat{\beta}'X'Y \quad (8)$$

$$\text{de donde } e'e = Y'Y - \hat{\beta}'X'Y = Y'Y - \hat{\beta}'X'X\hat{\beta} \quad (9)$$

$e'e$ se llamará suma de cuadrados de los residuos (SCR)

Como $\hat{\Theta} = X\hat{\beta}$ es único vemos que \hat{Y} , e y SCR son únicos independientemente del rango de X .

Teorema: Supongamos que X es una matriz $n \times p$ de rango p , y sea $P = X(X'X)^{-1}X'$

Entonces:

i) P y $I_n - P$ son simétricas e idempotentes

ii) $\text{rango}(I_n - P) = \text{tr}(I_n - P) = n - p$

iii) $PX = X$

Dem: i) $P' = (X(X'X)^{-1}X')' = X''[(X'X)^{-1}]'X' =$
 $= X((X'X)')^{-1}X' = X(X'X)^{-1}X' = P$

luego P es simétrica

$$(\mathbf{I}_n - P)' = \mathbf{I}_n' - P' = \mathbf{I}_n - P \text{ o sea } \mathbf{I}_n - P \text{ es simétrica}$$

$$P^2 = X \underbrace{(X'X)^{-1}X'}_{\mathbf{I}_p} X (X'X)^{-1}X' = X \mathbf{I}_p (X'X)^{-1}X' = P$$

$$(\mathbf{I}_n - P)^2 = \mathbf{I}_n - 2P + P^2 = \mathbf{I}_n - P$$

ii) Dado que $\mathbf{I}_n - P$ es simétrica e idempotente (pre-requisitos) tenemos que

$$\text{rango}(\mathbf{I}_n - P) = \text{tr}(\mathbf{I}_n - P) = n - \text{tr}(P)$$

$$\begin{aligned} \text{tr}(P) &= \text{tr}(X(X'X)^{-1}X') = \text{tr}(X'X(X'X)^{-1}) \textcircled{*} \\ &= \text{tr}(\mathbf{I}_p) = p \end{aligned}$$

$\textcircled{*}$ pre-requisitos ($\text{tr}(AC) = \text{tr}(CA)$)

$$\text{iii) } PX = X(X'X)^{-1}X'X = X$$

Teorema: Sea el modelo lineal $Y = X\beta + \varepsilon$
con $\text{rango}(X) = p$

i) Si suponemos que $E(\varepsilon) = 0$ (o sea los errores son insesgados) entonces

$\hat{\beta} = (X'X)^{-1}X'Y$ es un estimador insesgado de β

ii) Si además asumimos que los errores son no correlacionados y que tienen la misma varianza, es decir $\text{Var}(\varepsilon) = \sigma^2 I_n$ entonces

$$\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$$

Dem: i) $E(\hat{\beta}) = (X'X)^{-1}X'E(Y) =$
 $= (X'X)^{-1}X'E(X\beta) = (X'X)^{-1}X'X\beta = \beta$ pues $E(\varepsilon) = 0$

ii) $\text{Var}(Y) = \text{Var}(Y - X\beta) = \text{Var}(\varepsilon) = \sigma^2 I_n$

$$\text{Var}(\hat{\beta}) = \text{Var}((X'X)^{-1}X'Y) = \quad V(AZ) = AV(Z)A'$$

$$= (X'X)^{-1}X' \text{Var}(Y) (X'X)^{-1}X' =$$

$$= (X'X)^{-1} X' \underbrace{\text{Var}(Y)}_{\sigma^2 I_n} X (X'X)^{-1}$$

$$= \sigma^2 (X'X)^{-1} X' X (X'X)^{-1} = \sigma^2 (X'X)^{-1}$$

Consideremos $\Theta = X\beta$ y sea la combinación lineal $c'\Theta$. El teorema que sigue responde cual es el "mejor" (en algún sentido) estimador de esta magnitud

Teorema: Sea $\hat{\Theta}$ el estimador de mínimos cuadrados de $\Theta = X\beta$ con $\Theta \in \Omega$ (el espacio generado por las columnas de X) y X puede no tener rango completo.

Entonces dentro de los estimadores lineales insesgados de $c'\Theta$ se tiene que $c'\hat{\Theta}$ es el único estimador de mínima varianza de $c'\Theta$

Dem: Ya vimos que $\hat{\Theta} = PY$ y

$$\underline{P\Theta = PX\beta = X\beta = \Theta, \text{ pues } PX = X}$$

$$\text{luego } E(c'\hat{\Theta}) = E(c'PY) = c'P E(Y) =$$

$$= c'P E(X\beta + \varepsilon) = c'PX\beta = c'P\Theta = c'\Theta$$

para todo $\Theta \in \Omega$

o sea $c'\hat{\theta}$ es un estimador sesgado de $c'\theta$

$$\text{Nótese que } c'\hat{\theta} = c'PY = (Pc)'\gamma$$

Consideremos $d'\gamma$ otro estimador lineal sesgado de $c'\theta$.

$$\text{Entonces: } c'\theta = E(d'\gamma) = d'\theta \quad \text{o sea} \\ (c-d)'\theta = 0$$

luego $(c-d) \perp \Omega$

Por lo tanto $P(c-d) = 0$ de donde $Pc = Pd$

$$\text{Var}(c'\hat{\theta}) = \text{Var}(Pc)'\gamma = \text{Var}(Pd)'\gamma = \\ = (Pd)'\underbrace{\text{Var}(\gamma)}_{\sigma^2 I_n} (Pd) = \sigma^2 d'P'Pd = \sigma^2 d'P^2d = \sigma^2 d'Pd$$

$d' \overset{\sigma^2 I}{\text{Var}(\gamma)} d = \sigma^2 d'd$

$$\text{así que } \text{Var}(d'\gamma) - \text{Var}(c'\hat{\theta}) = \text{Var}(d'\gamma) - \sigma^2 d'Pd$$

$$= \sigma^2 (d'd - d'Pd) = \sigma^2 d'(I_n - P)d =$$

$$= \sigma^2 d'(I_n - P)'(I_n - P)d = \sigma^2 \|(I_n - P)d\|^2 \geq 0$$

donde la igualdad se da cuando $(I_n - P)d = 0$

o sea $d = Pd = Pc$ de donde $c'\hat{\theta}$ es el estimador lineal de mínima varianza y es único.

obs

$$\begin{aligned} d'\gamma &= (Pc)'\gamma = \\ &= c'PY = c'\hat{\theta} \end{aligned}$$

Corolario: Si X tiene rango completo, entonces $a'\hat{\beta}$ es el estimador lineal de mínima varianza de $a'\beta$ para todo vector a

Este corolario es el conocido teorema de Gauss-Markov

Estimación Insesgada de σ^2

Teorema: Si $E(Y) = X\beta$ donde X es una matriz $n \times p$ de rango p y $\text{Var}(Y) = \sigma^2 I_n$ entonces

$$S^2 = \frac{(Y - \hat{\theta})'(Y - \hat{\theta})}{n-p} = \frac{SCR}{n-p}$$

es un estimador insesgado de σ^2 .

Dem: Consideremos la representación

$$\theta = X\beta$$

Entonces

$$Y - \hat{\theta} = (I_n - P)Y$$

donde $P = X(X'X)^{-1}X'$

Se tiene que

$$(n-p)S^2 = Y'(I_n - P)'(I_n - P)Y = Y'(I_n - P)^2 Y = Y'(I_n - P)Y$$

En lo que sigue usaremos que si U es un vector $n \times 1$ y A una matriz simétrica $n \times n$. Si $E(U) = \mu$ y $\text{Var}(U) = \Sigma$ entonces:

$$Y_i = \beta_0 + \varepsilon_i$$

$$\begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \beta_0 \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

$$(X'X) = n$$

$$(X'X)^{-1} = \frac{1}{n}$$

$$X'Y = \sum y_i$$

$$\beta_0 = \frac{\sum y_i}{n}$$

$$\hat{\beta} = (X'X)^{-1}X'Y$$

$$E(U'AU) = \text{tr}(A\Sigma) + y'Ay$$

Como $(I_n - P)$ es simétrica y $\text{Var}(Y) = \sigma^2 I$ y

además $E(Y) = X\beta = \theta$

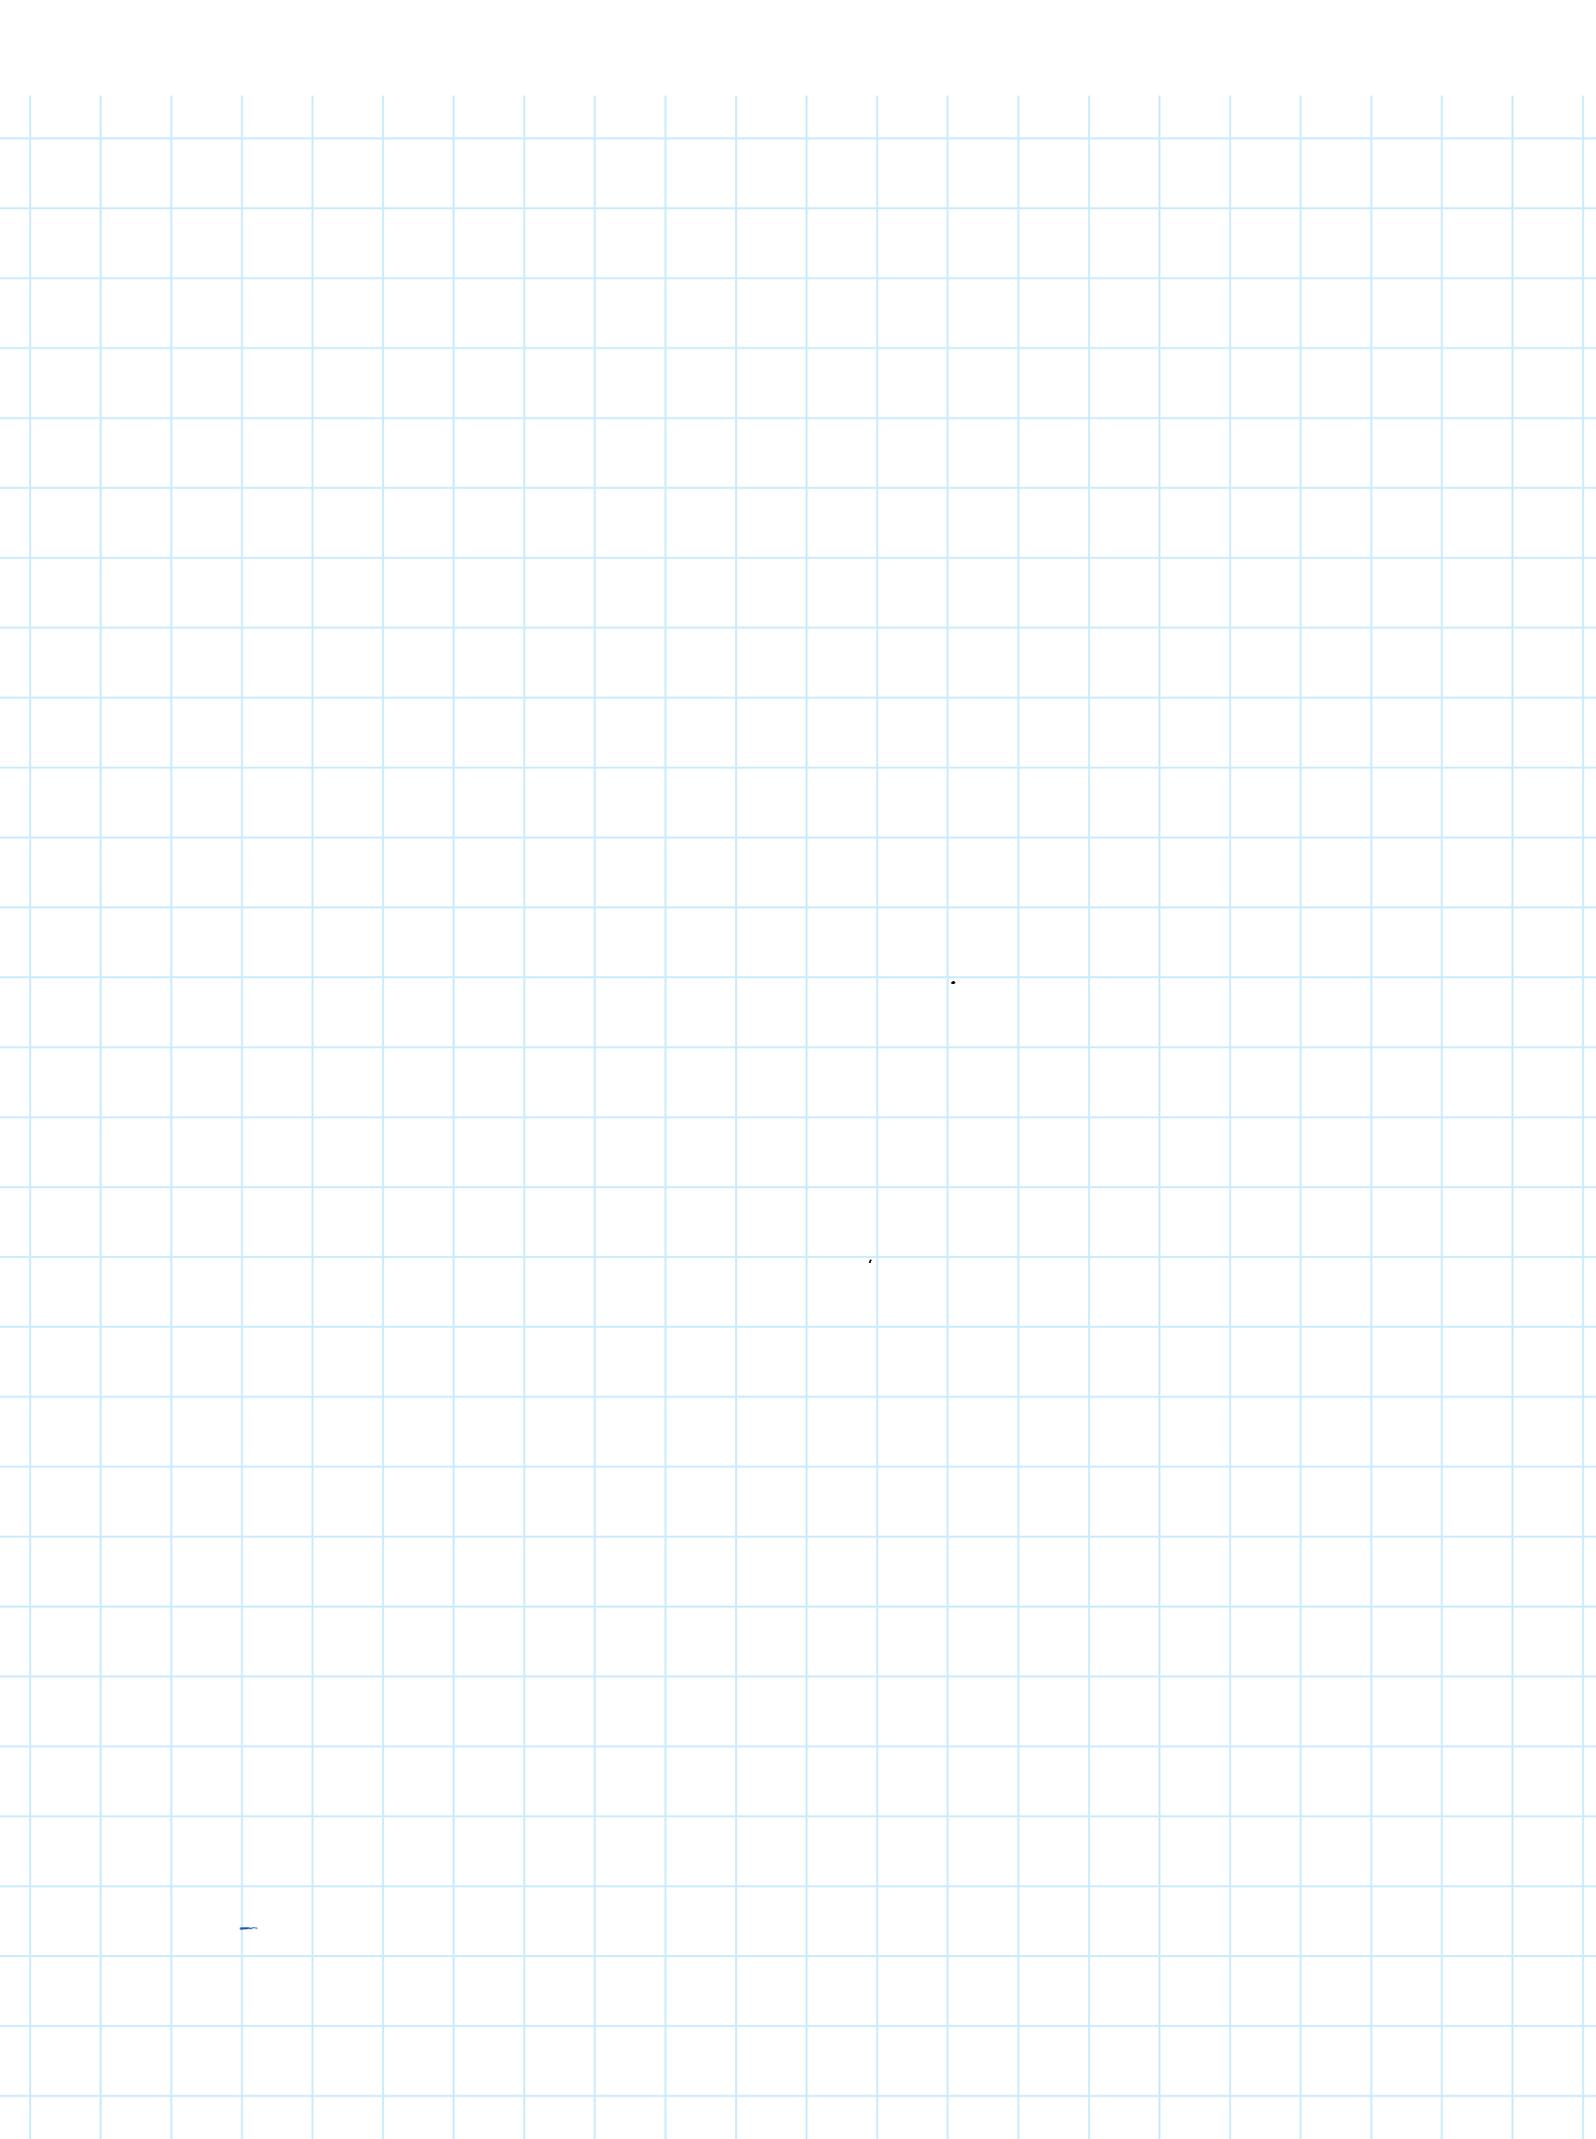
$$P\theta = X(X'X)^{-1}X'X\beta = X\beta = \theta$$

$$E(Y'(I_n - P)Y) = \text{tr}((I_n - P)\sigma^2 I_n) + E(Y)'(I_n - P)E(Y)$$

$$= \sigma^2 \underbrace{\text{tr}(I_n - P)}_{n-p} + \underbrace{\theta'(I_n - P)\theta}_0 = \sigma^2 (n-p)$$

de donde $E(S^2) = \sigma^2$

→ a cargo del lector



Hasta ahora los únicos hipotesis que hemos impuesto fue que $E(\varepsilon) = 0$ y $\text{Var}(\varepsilon) = \sigma^2 I_n$.
 Si suponemos además que $\varepsilon \sim N_n(0, \sigma^2 I_n)$ obtendremos la teoría asintótica.
 Comencemos conociendo la distribución normal multivariada.

Definición: Sea Σ una matriz definida positiva $n \times n$ y μ un vector $n \times 1$.
 llamaremos función de distribución normal multivariada aquella distribución que tenga densidad

$$f(y_1, \dots, y_n) = \frac{1}{(2\pi)^{n/2} \det(\Sigma)^{1/2}} e^{-\frac{1}{2}(y-\mu)' \Sigma^{-1} (y-\mu)}$$

Como Σ es definida positiva y por lo tanto lo es Σ^{-1} y por lo tanto la forma cuadrática $(y-\mu)' \Sigma^{-1} (y-\mu) \geq 0$ luego $f(y_1, \dots, y_n)$ es acotada y toma su máximo en $y = \mu$ y vale $(2\pi)^{-n/2} \det(\Sigma)^{-1/2}$.

Debemos ver que efectivamente f es una densidad.
 Como Σ es definida positiva tiene una raíz cuadrada simétrica definida positiva $\Sigma^{1/2}$ que satisface

$$(\Sigma^{1/2})^{-1} = \Sigma^{-1/2}$$

Sea $z = \Sigma^{-1/2}(y - \mu)$ por lo que $y = \Sigma^{1/2}z + \mu$

El jacobiano de esta transformación es:

$$J = \det\left(\frac{\partial y_i}{\partial z_j}\right) = \det(\Sigma^{1/2}) = [\det(\Sigma)]^{1/2}$$

luego

$$\int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} e^{-\frac{1}{2}(y-\mu)' \Sigma^{-1}(y-\mu)} dy_1 \dots dy_n =$$

$$= \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} e^{-\frac{1}{2}z' \Sigma^{1/2} \Sigma^{-1} \Sigma^{1/2} z} |J| dz_1 \dots dz_n =$$

$$= \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} e^{-\frac{1}{2}z'z} |J| dz_1 \dots dz_n =$$

$$= |J| \prod_{i=1}^n \int_{-\infty}^{+\infty} e^{-\frac{1}{2}z_i^2} dz_i = |J| \prod_{i=1}^n (2\pi)^{1/2} =$$

$$= (2\pi)^{n/2} \det(\Sigma)^{1/2}$$

Como $f > 0$ se sigue que es una densidad pues

$$\int_{\mathbb{R}^n} f(y_1, \dots, y_n) dy_1 \dots dy_n = 1$$

Teorema: Si un vector aleatorio Y tiene distribución normal multivariada entonces $E(Y) = \mu$ y $\text{Var}(Y) = \Sigma$

$$E(Y) = \mu \quad \text{y} \quad \text{Var}(Y) = \Sigma$$

Dem: Sea $Z = \Sigma^{-1/2}(Y - \mu)$

Igual que antes usando la fórmula de cambio de variable tenemos que Z tiene densidad

$$\begin{aligned} f(z_1, \dots, z_n) &= f(Y(Z)) |J| = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z_i^2} \\ &= \frac{1}{(2\pi)^{n/2}} e^{-\frac{1}{2}z^T z} \end{aligned}$$

Por lo tanto la factorización anterior implica que los Z_i son independientes con $Z_i \sim N(0, 1)$.

Es decir $E(Z) = 0$ y $\text{Var}(Z) = I_n$ luego

$$E(Y) = E(\Sigma^{1/2} Z + \mu) = \Sigma^{1/2} E(Z) + \mu = \mu$$

$$\text{Var}(Y) = \text{Var}(\Sigma^{1/2} Z + \mu) = \text{Var}(\Sigma^{1/2} Z) =$$

$$= \Sigma^{1/2} \text{Var}(Z) \Sigma^{1/2} = \Sigma^{1/2} I_n \Sigma^{1/2} = \Sigma$$

Para indicar que Y tiene distribución normal multivariada con $E(Y) = \mu$ y $\text{Var}(Y) = \Sigma$ utilizaremos la notación $Y \sim N(\mu, \Sigma)$

Si $Y \sim N(\mu, \Sigma)$ vemos que $Z = \Sigma^{-1/2}(Y - \mu)$ tiene $Z \sim N(0, I_n)$. Z es el análogo de la estandarización en una dimensión

Función Generatriz de Momentos

Definición: Si X es un vector aleatorio $n \times 1$, y t un vector de constantes $n \times 1$ definamos la función generatriz de momentos de X mediante

$$M_X(t) = E(e^{t'X})$$

Un resultado importante es que si $M_X(t)$ existe para todo t , tal que $\|t\| \leq t_0$ ($t_0 > 0$) entonces $M_X(t)$ determina la distribución de X

Sea $X_1 = (x_1, \dots, x_r)'$, $X_2 = (x_{r+1}, \dots, x_n)'$

se prueba que X_1 y X_2 son independientes si

$$\text{y solo si } M_X(t) = a(t_1, \dots, t_r) b(t_{r+1}, \dots, t_n)$$

para algunas funciones $a(\cdot)$ y $b(\cdot)$

También lo serán si

$$M_X(t) = M_X(t_1, \dots, t_r, 0, \dots, 0) M_X(0, \dots, 0, t_{r+1}, \dots, t_n)$$

$$\text{Si } Z \sim N_n(0, I_n) \Rightarrow E(e^{t'Z}) = e^{\frac{1}{2} t' t}$$

$$\text{Si } Y \sim N_n(\mu, \Sigma) \Rightarrow E(e^{t'Y}) = e^{t'\mu + \frac{1}{2} t' \Sigma t}$$

Veamos la función generatriz de la normal multivariada.

Primero consideremos el caso $Z \sim N(0, I_n)$ entonces por la independencia de los Z_i la

función generatriz de momentos de Z es:

$$E(e^{t'Z}) = E\left(e^{\sum_{i=1}^n t_i z_i}\right) = E\left(\prod_{i=1}^n e^{t_i z_i}\right) \\ = \prod_{i=1}^n E(e^{t_i z_i}) = \prod_{i=1}^n e^{t_i^2/2} = e^{\frac{1}{2}t't}$$

donde hemos usado que si $z_i \sim N(0,1) \Rightarrow$

$$E(e^{t_i z_i}) = e^{t_i^2/2}$$

Si $Y \sim N_n(\mu, \Sigma)$ podemos escribir $Y = \Sigma^{1/2} Z + \mu$

con $Z \sim N_n(0, \Sigma^{-1})$. Si hacemos $s = \Sigma^{1/2} t$ tenemos

$$E(e^{t'Y}) = E\left(e^{t'(\Sigma^{1/2} Z + \mu)}\right) = \\ = E\left(e^{s'Z}\right) e^{t'\mu} = e^{\frac{1}{2}s's} e^{t'\mu} = \\ = e^{\frac{1}{2}t'\Sigma^{1/2}\Sigma^{1/2}t + t'\mu} = e^{t'\mu + \frac{1}{2}t'\Sigma t}$$

Teorema: Sea $Y \sim N_n(\mu, \Sigma)$ y C una matriz $m \times n$ de rango m y d un vector $m \times 1$.
Entonces $CY + d \sim N_m(C\mu + d, C\Sigma C')$

Dem: La función generatriz de momentos de $CY + d$ es:

$$E\left(e^{t'(CY+d)}\right) = E\left(e^{(C't)'Y + t'd}\right) =$$

$$E(e^{t'(cY+d)}) = E(e^{(c't)'Y + t'd}) = e^{(c't)' \mu + \frac{1}{2} (c't)' \Sigma c't + t'd} = e^{t'(c\mu + d) + \frac{1}{2} t' C \Sigma C' t}$$

Dado que $C \Sigma C'$ es definida positiva la ecuación de arriba es la función generatriz de momentos de $N_m(c\mu + d, C \Sigma C')$. Observamos que $C \Sigma C'$ es definida positiva y que Σ es σ y C es de rango m .

Corolario Si $Y = AZ + \mu$ con A una matriz $n \times m$ no singular entonces $Y \sim N_n(\mu, A \Delta A')$

Necesitaremos a veces trabajar con vectores aleatorios de la forma CY donde Y es normal pero C no es de rango completo, por ejemplo vectores de residuos, de ajustes.

Si $Z \sim N_m(0, I_m)$, A una matriz $n \times m$, μ un vector $n \times 1$ reemplazando $\Sigma^{1/2}$ por A en la obtención de la matriz generadora de momentos de la normal se obtiene que la función generatriz de momentos de $Y = AZ + \mu$ es:

$$e^{t'\mu + \frac{1}{2} t' A A' t}$$

Notemos que $E(Y) = A E(Z) + \mu = \mu$, $\text{Var}(Y) = A \text{Var}(Z) A' = A A'$

Estos resultados motivan definir:

Definición: Un vector aleatorio Y , $n \times 1$ con media μ y varianza Σ , tiene una distribución normal multivariada

si tiene la misma distribución de $AZ + \mu$ donde A es cualquier matriz $n \times m$ que satisfice $\Sigma = AA'$ y $Z \sim N_m(0, I_m)$. Escriviremos que $Y \sim AZ + \mu$ para indicar que Y y $AZ + \mu$ tienen la misma distribución.

Es fácil verificar que si Σ es definida positiva la nueva definición es equivalente a la veje.

Si Σ es de rango $m < n$ la distribución de Y no puede ser expresada en términos de la función de densidad. En ambos casos la función generatriz de momentos es

$$e^{t'\mu + \frac{1}{2}t'\Sigma t}$$

Escribiremos $Y \sim N_n(\mu, \Sigma)$. Cuando Σ tiene rango completo decimos a veces que Y tiene distribución singular.

Teorema: Un vector aleatorio Y con matriz de varianzas-covarianza Σ y vector de medias μ tiene distribución normal $N_n(\mu, \Sigma)$ si y solo si $a'Y$ tiene distribución normal univariada para todo vector a .

Dem: Se omite.

Independencia Estadística

Ya sabemos que si tenemos un par de variables independientes son no correlacionados. Para el caso de la distribución

normal el recíproco es verdadero.

Teorema: Sea $Y \sim N_n(\mu, \Sigma)$ y que Y, μ, Σ se pueden particionar como:

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix}, \quad \mu = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$$

de manera conformable.

Entonces Y_1, Y_2 son independientes si, y solo si $\Sigma_{12} = 0$

Dem: La f.g.m de Y es $e^{t'\mu + \frac{1}{2}t'\Sigma t}$

Particionemos t conformablemente con Y . Entonces

$$t_1'\mu_1 + t_2'\mu_2 + \frac{1}{2}t_1'\Sigma_{11}t_1 + \frac{1}{2}t_2'\Sigma_{22}t_2 + t_1'\Sigma_{12}t_2$$

Si $\Sigma_{12} = 0$ entonces la función generatriz de momentos puede ser factorizada en términos de t_1, t_2 separadamente lo que implica que Y_1, Y_2 son independientes

Inversamente si Y_1, Y_2 son independientes \Rightarrow

$$\pi(t_1, 0) \pi(0, t_2) = \pi(t_1, t_2)$$

donde π es la f.g.m de Y .

Por lo anterior esto implica que $t_1'\Sigma_{12}t_2 = 0$ para todo t_1, t_2 lo cual implica que $\Sigma_{12} = 0$ (esto se sigue poniendo $t_1 = (1, 0, \dots, 0)'$ etc)

Teorema: Sea $Y \sim N_n(\mu, \Sigma)$, sea $U = AY, V = BY$
Entonces U, V son independientes si y solo si
 $Cov(U, V) = A\Sigma B' = 0$

Dem: A cargo del lector.

Distribución de los Estimadores

Teorema: Si $Y \sim N_n(X\beta, \sigma^2 I_n)$ donde X es
 $n \times p$ de rango p entonces

i) $\hat{\beta} \sim N_p(\beta, \sigma^2 (X'X)^{-1})$

ii) $\frac{(\hat{\beta} - \beta)' X'X (\hat{\beta} - \beta)}{\sigma^2} \sim \chi_p^2$

iii) $\hat{\beta}$ es independiente de S^2

iv) $\frac{RSS}{\sigma^2} = \frac{(n-p)S^2}{\sigma^2} \sim \chi_{n-p}^2$

Dem: i) Dado que $\hat{\beta} = (X'X)^{-1} X'Y = CY$

donde C es una matriz $p \times n$ tal que

$$\text{rango}(C) = \text{rango}(X') = \text{rango } X = p$$

$$(\text{rang}(\Delta) = \text{rang}(\Delta') = \text{rang}(\Delta'\Delta))$$

Entonces $\hat{\beta}$ tiene distribución normal multivariada con $E(\hat{\beta}) = \beta$ y $\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$

$$u) (\hat{\beta} - \beta)' \frac{X'X}{\sigma^2} (\hat{\beta} - \beta) = (\hat{\beta} - \beta)' (\text{Var}(\hat{\beta}))^{-1} (\hat{\beta} - \beta) \text{ la}$$

cual tiene distribución χ^2_p por i) y porque si

$Y \sim N_n(Y, \Sigma)$ con Σ definida positiva \Rightarrow

$Q = (Y - Y)' \Sigma^{-1} (Y - Y) \sim \chi^2_n$ (veremos en demostración más adelante)

$$iii) \text{Cov}(\hat{\beta}, Y - X\hat{\beta}) = \text{Cov}((X'X)^{-1}X'Y, (I_n - P)Y)$$

$$= (X'X)^{-1}X' \text{Cov}(Y) (I_n - P)' = \sigma^2 (X'X)^{-1}X' (I_n - P)$$

$$= \sigma^2 ((X'X)^{-1}X' - (X'X)^{-1}X'P) =$$

$$= \sigma^2 ((X'X)^{-1}X' - \overbrace{(X'X)^{-1}X'X}^I (X'X)^{-1}X') = 0$$

Esto implica que $\hat{\beta}$ y $Y - X\hat{\beta}$ son independientes por lo que $\hat{\beta}$ y $\|Y - X\hat{\beta}\|^2$ son independientes o sea

$\hat{\beta}$ y S^2 son independientes.

$$w) \text{RSS} = Y'(I_n - P)Y = \underbrace{(Y - X\hat{\beta})'(I_n - P)(Y - X\hat{\beta})}_{\oplus}$$

$$= \varepsilon'(I_n - P)\varepsilon$$

$$b) (I_{n-p})X\beta = X\beta - \frac{P X \beta}{X\beta} = 0 \quad y \quad (X\beta)'(I_{n-p}) = ((I_{n-p})X\beta)' = 0$$

$$c) \beta' X' \underbrace{(I_{n-p})X\beta}_0 = 0$$

Tenemos que $RSS = \varepsilon' (I_n - P) \varepsilon$ con

I_{n-p} idempotente, simétrica y de rango $n-p$

Además $\varepsilon \sim N_n(0, \sigma^2 I_n)$

Se aplicamos el resultado que dice que si $Y \sim N_n(0, I_n)$ y A una matriz simétrica entonces $Y'AY \sim \chi^2_r$ si y solo si A es idempotente de rango r (lo demostraremos más adelante)
obtenemos que $\frac{RSS}{\sigma^2} \sim \chi^2_{n-p}$

Estimación Máximo Verosímil

