

1. Modelo lineal Base

Consideren el modelo de regresión usual:

$$\textcircled{1} \quad y_i = x_i' \beta + u_i, \quad E[u_i | x_i] = 0 \quad (\text{no hay correlación entre cada variable dentro del vector } x_i \text{ y el término de error } u_i).$$

En forma matricial

$$y = X\beta + u,$$

donde $y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}_{n \times 1}$, $X = \begin{bmatrix} x_1' \\ x_2' \\ \vdots \\ x_n' \end{bmatrix}_{n \times k}$.

* Noten que $E[u_i | x_i] = 0$ es un supuesto MUCHO más fuerte porque significa $E[g(x_i)u_i] = 0$. Es decir, u_i no se correlaciona con ninguna función de x_i .

1.1. Identificación

Suponemos

(i) $E[x_i u_i] = 0$

(ii) $E[x_i x_i']$ tiene rango completo. Es decir, $\text{rank}(E[x_i x_i']) = k$.

Entonces partimos de (i):

$$E[x_i u_i] = 0$$

$$\Rightarrow E[x_i (y_i - x_i' \beta)] = 0$$

$$\Rightarrow E[x_i y_i] - E[x_i x_i'] \beta = 0$$

Si $E[x_i x_i']$ es invertible (lo es, dado por (ii)), entonces

$$\beta = (E[x_i x_i'])^{-1} E[x_i y_i] \quad \textcircled{2}$$

Además, podemos estimar reemplazando esperanzas por promedios muestrales.

A esto se le llama **sample analogue**. Tenemos:

$$\begin{aligned} \hat{\beta} &= \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n x_i y_i \\ &\stackrel{\text{reemplazo}}{=} \beta + \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n x_i u_i \end{aligned} \quad \textcircled{3}$$

1.2 Insesgadez de OLS

Partimos de ③

$$\hat{\beta} = \beta + \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n x_i u_i$$

Tomando esperanza condicionada

$$E[\hat{\beta} | X] = \beta + \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n x_i \underbrace{E[u_i | X]}$$

solo es 0 si $E[u_i | X] = 0$.

Si solo asumimos $E[u_i | x_i] = 0$

NO es insesgado.

Importantemente, OLS es **sesgado** en muestras finitas,

excepto cuando ponemos un supuesto de **mean independence** $E[u_i | x_i] = 0$. Es decir,

cundo $E[u_i | x_i] = x_i' \beta$, que significa que estamos especificando correctamente el modelo.

2. Teoría Asintótica

- Teorema 1** - (Continuous Mapping) Sea $\{x_n\} \in \mathbb{R}^d$ tal que $x_n \xrightarrow{d} X$. Además, sea $g(\cdot) : \mathbb{R}^d \rightarrow \mathbb{R}^k$ que es continuo en un set G tal que $P\{X \in G\} = 1$. Entonces

$$g(x_n) \xrightarrow{d} g(X) \quad \text{cuando } n \rightarrow \infty.$$

$$\textcircled{*} \text{ ejemplo, } g\left(\begin{bmatrix} a \\ b \end{bmatrix}\right) = a+b \Rightarrow x_{1n} + x_{2n} \xrightarrow{d} x_1 + x_2$$

- Teorema 2** - (Slutsky) Suponemos que hay $\{x_n\}$ tal que $x_n \xrightarrow{p} X$ y que $g(\cdot)$ nuevamente es una función continua en un set tal que $P\{X \in G\} = 1$. Entonces,

$$h(x_n) \xrightarrow{p} h(X).$$

- Teorema 3** - (Ley Débil Grandes Números **WLLN**, iid) Sea $\{x_n\}$ una secuencia de iid vectores aleatorios tal que $E\|x_i\| < \infty$. Entonces

$$\frac{1}{n} \sum_{i=1}^n x_i \xrightarrow{p} E x_i$$

- Teorema 4** - (Lmite Central **CLT**, iid) Sea $\{x_n\}$ una secuencia de iid vectores aleatorios tal que $E\|x_i\|^2 < \infty$ y $\text{Var}(x_i) = \Sigma$, donde Σ es no singular. Entonces,

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (x_i - E x_i) \xrightarrow{d} N(0, \Sigma)$$

$$\textcircled{*} \text{ Var}(x_i) = E[(x_i - E x_i)(x_i - E x_i)'] = E[x_i x_i' - (E x_i) x_i'] \\ \in E\|x_i\|^2 + [E\|x_i\|]^2 = O(1) \quad \text{si} \quad E\|x_i\|^2 = O(1).$$

3. Propiedades del Estimador $\hat{\beta}$

3.1. Consistencia

Def. Decimos que $\hat{\beta}$ es consistente si $\hat{\beta} \xrightarrow{p} \beta$.

Para mostrar esta propiedad damos los siguientes supuestos.

- (i) Data $\{y_i, x_i'\}$ es iid
- (ii) $E x_i u_i = 0$
- (iii) $E x_i x_i'$ tiene rango completo K

Si (i)-(iii) se cumplen, entonces

$$\hat{\beta}_n = \beta + o_p(1)$$

↑
subíndice n
para ser explícitos que
cambia con n.

proof.

$$\hat{\beta}_n = \beta + \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n x_i u_i$$

Por el Teorema 3 (WLLN) tenemos $\frac{1}{n} \sum_{i=1}^n x_i x_i' \xrightarrow{p} E x_i x_i'$ y $\frac{1}{n} \sum_{i=1}^n x_i u_i = E x_i u_i = 0$.

Además $g(z) = z^{-1}$ es continua siempre que $z \neq 0$. Entonces, por el Teorema 2 (Slutsky)

$$\left[\frac{1}{n} \sum_{i=1}^n x_i x_i' \right]^{-1} \xrightarrow{p} [E x_i x_i']^{-1}.$$

Entonces, escribimos

$$\begin{aligned} \hat{\beta}_n &= \beta + \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n x_i u_i \\ &\stackrel{\text{WLLN}}{=} \beta + \left(E x_i x_i' + o_p(1) \right)^{-1} \left(\underbrace{E x_i u_i}_{=0} + o_p(1) \right) \\ &\stackrel{\text{Slutsky}}{=} \beta + \left((E x_i x_i')^{-1} + o_p(1) \right) (0 + o_p(1)) \\ &= \beta + (o(1) + o_p(1)) o_p(1) \\ &\quad \text{E} x_i x_i' > 0 \Rightarrow (E x_i x_i')^{-1} = o(1) \\ &= \beta + o_p(1). \quad \blacksquare \end{aligned}$$

3.2. Normalidad Asintótica

Para mostrar ello, primero daremos explícitamente los supuestos

- (i) Data $\{y_i, x_i'\}$ es iid
- (ii) $E x_i u_i = 0$
- (iii) $E x_i x_i'$ tiene rango completo K
- (iv) $E x_{ij}^4 < \infty$ para $j=1, \dots, K$.
- (v) $E u_i^4 < \infty$
- (vi) $\text{Var}(u_i x_i)$ es positiva definida

Lema:- Si (ii), (iv) y (v) se cumplen, entonces
 $\text{Var}(u_i x_i) = O(1)$.

Proof:-

$$\begin{aligned} \text{Var}(x_i u_i) &= E \left[\underbrace{(u_i x_i)}_{K \times K} - E u_i x_i \right) \left(\underbrace{u_i x_i}_{K \times 1} - E u_i x_i \right)' \underbrace{\quad}_{K \times K} \right] \\ &\stackrel{\text{por (ii)}}{=} E \left[u_i x_i u_i x_i' \right] \\ &= E \left[u_i^2 x_i x_i' \right] \end{aligned}$$

$$\stackrel{\text{Cauchy Schwarz}}{\leq} \left\{ E |u_i|^4 \cdot E \|x_i x_i'\|^2 \right\}^{1/2}$$

$$\stackrel{\text{Frobenius norm}}{=} \left\{ E |u_i|^4 \cdot E [\text{tr}(x_i x_i' x_i x_i')] \right\}^{1/2}$$

$$\stackrel{\text{Propiedad de tr}(\cdot)}{=} \left\{ E |u_i|^4 \cdot E [\text{tr}(\underbrace{x_i' x_i}_{1 \times 1} \underbrace{x_i x_i'}_{K \times 1})] \right\}^{1/2}$$

$$= \left\{ E |u_i|^4 \cdot E [x_i' x_i]^2 \right\}^{1/2}$$

$$\stackrel{\text{Definición de norma } \|x\|^2 = x'x}{=} \left\{ E |u_i|^4 \cdot E \|x_i\|^4 \right\}^{1/2}$$

$$= \left\{ E |u_i|^4 \cdot E \left[\sum_{j=1}^K x_{ij}^2 \right]^2 \right\}^{1/2}$$

$$\leq \left\{ E |u_i|^4 \cdot E \left[K \max_{1 \leq j \leq K} x_{ij}^2 \right]^2 \right\}^{1/2}$$

$$\leq \left\{ E |u_i|^4 \cdot K^2 \max_{1 \leq j \leq K} E [x_{ij}^4] \right\}^{1/2}$$

$$\stackrel{\text{por (iv) (v)}}{=} O(1) \cdot O(1)$$

$$= O(1) \quad \blacksquare$$

Ahora, si se cumplen (i) - (vi), entonces

$$\sqrt{n} (\hat{\beta}_n - \beta) \xrightarrow{d} \mathcal{N} \left(0, \underbrace{(E X_i X_i')^{-1} \text{Var}(X_i u_i) (E X_i X_i')^{-1}}_{V := \text{varianza asintótica}} \right)$$

⊛ Noten que esto implica $\hat{\beta}_n = \beta + \underbrace{O_p(n^{-1/2})}_{\rightarrow \text{esto es el ruido estadístico}}.$

proof:

Empecemos notando lo siguiente dado por (ii)

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i = \frac{1}{\sqrt{n}} \sum_{i=1}^n \underbrace{(x_i u_i - E X_i u_i)}_{\text{porque } = 0}$$

Además, por el lema anterior y por (i), (vi) cumple con los requisitos del CLT.
Entonces,

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i \xrightarrow{d} \mathcal{N}(0, \text{Var}(X_i u_i))$$

⊛ Es decir, $\frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i = O_p(1).$

Ahora, procedamos a escribir

$$\sqrt{n} (\hat{\beta}_n - \beta) = \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i$$

WLLN + Slutsky

$$= \left((E X_i X_i')^{-1} + o_p(1) \right) \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i$$

$$= (E X_i X_i')^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i + o_p(1) \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i$$

$$= (E X_i X_i')^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i + o_p(1) O_p(1)$$

$$= (E X_i X_i')^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i + o_p(1)$$

$$= \frac{1}{\sqrt{n}} \sum_{i=1}^n \underbrace{(E X_i X_i')^{-1} x_i u_i}_{\sum_i}$$

El **CLT** requiere que $\text{Var}(\xi_i) = E[\xi_i \xi_i']$ sea finita y definida positiva.
 En primer lugar es finita porque

$$\begin{aligned}\text{Var}(\xi_i) &= E(X_i X_i')^{-1} \text{Var}(X_i u_i) E(X_i X_i')^{-1} \\ &= O(1) \cdot O(1) \cdot O(1) \\ &= O(1),\end{aligned}$$

dado por $E X_i X_i'$ de rango completo.

Además, $E X_i X_i' = O(1)$ porque $E \|X_i X_i'\| \leq E \|X_i\|^2 = O(1)$. Por lo tanto su inversa $(E X_i X_i')^{-1}$ no puede ser singular. Esto, junto con **(vi)** aseguran que $\text{Var}(\xi_i)$ cumpla con ser positiva definida.

Entonces,

$$\sqrt{n}(\hat{\beta}_n - \beta) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \underbrace{(E X_i X_i')^{-1} X_i u_i}_{\xi_i} + o_p(1)$$

$$\rightarrow N\left(0, \underbrace{E(X_i X_i')^{-1} \text{Var}(X_i u_i) E(X_i X_i')^{-1}}_{V := \text{varianza asintótica}}\right).$$

3.3. Estimación de Varianza Asintótica

Denotamos

$$\hat{M}_n = \frac{1}{n} \sum_{i=1}^n X_i X_i', \quad \hat{Q}_n = \frac{1}{n} \sum_{i=1}^n \hat{u}_i^2 X_i X_i', \quad \hat{u}_i = y_i - X_i' \hat{\beta}_n.$$

Proponemos estimar V usando

$$\hat{V}_n = \hat{M}_n^{-1} \hat{Q}_n \hat{M}_n^{-1}.$$

Para probar su consistencia, observemos lo siguiente

$$\begin{aligned}\hat{Q}_n &= \frac{1}{n} \sum_{i=1}^n \hat{u}_i^2 X_i X_i' \\ &= \frac{1}{n} \sum_{i=1}^n [(y_i - X_i' \hat{\beta}_n + X_i' \beta)^2] X_i X_i' \\ &= \frac{1}{n} \sum_{i=1}^n [(u_i - X_i' (\hat{\beta}_n - \beta))^2] X_i X_i'\end{aligned}$$

$$\begin{aligned}
&= \frac{1}{n} \sum_{i=1}^n u_i^2 x_i x_i' + \underbrace{\frac{1}{n} \sum_{i=1}^n [x_i' (\hat{\beta}_n - \beta)]^2 x_i x_i'}_{R_{1n}} - \underbrace{\frac{2}{n} \sum_{i=1}^n [x_i' (\hat{\beta}_n - \beta) u_i] x_i x_i'}_{R_{2n}} \\
&= \Omega + o_p(1) + R_{1n} + R_{2n}
\end{aligned}$$

Si mostramos que R_{1n} y R_{2n} son $o_p(1)$ entonces nuestro estimador $\hat{\beta}_n$ es consistente.

Empezamos por R_{1n} :

$$\begin{aligned}
\bullet \quad \|R_{1n}\| &\leq \frac{1}{n} \sum_{i=1}^n |x_i' (\hat{\beta}_n - \beta)|^2 \|x_i x_i'\| \\
&\leq \frac{1}{n} \sum_{i=1}^n \|x_i\|^2 \|\hat{\beta}_n - \beta\|^2 \|x_i\|^2 \\
&\leq \underbrace{\|\hat{\beta}_n - \beta\|^2}_{o_p(1)} \underbrace{\frac{1}{n} \sum_{i=1}^n \|x_i\|^4}_{E \|x_i\|^4 + o_p(1)} \\
&= \|o_p(1)\|^2 (E \|x_i\|^4 + o_p(1))
\end{aligned}$$

$$\text{Slutsky} = o_p(1) (E \|x_i\|^4 + o_p(1))$$

$$\text{por (iv)} = o_p(1) (O(1) + o_p(1))$$

$$= o_p(1).$$

$$\begin{aligned}
\bullet \quad \|R_{2n}\| &\leq \frac{1}{n} \sum_{i=1}^n \|x_i' (\hat{\beta}_n - \beta) u_i\| \|x_i x_i'\| \\
&\leq \|\hat{\beta}_n - \beta\| \frac{1}{n} \sum_{i=1}^n |u_i| \|x_i\| \cdot \|x_i\|^2 \\
&= o_p(1) (E |u_i| \|x_i\| \|x_i\|^2 + o_p(1))
\end{aligned}$$

$$\text{Cauchy Schwarz} \leq o_p(1) \left((E |u_i|^2 \|x_i\|^2)^{1/2} (E \|x_i\|^4)^{1/2} + o_p(1) \right)$$

$$\text{Cauchy Schwarz} \leq o_p(1) \left[(E |u_i|^4 E \|x_i\|^4)^{1/4} (E \|x_i\|^4)^{1/2} + o_p(1) \right]$$

$$\text{por (iv), (v)} = o_p(1) [O(1) \cdot O(1) \cdot O(1) + o_p(1)]$$

$$= o_p(1).$$

Con esto hemos mostrado

$$\hat{\beta}_n = \beta + o_p(1).$$

Finalmente,

$$\begin{aligned}\hat{V}_n &= M_n^{-1} \hat{\Omega}_n \hat{M}_n^{-1} \\ &= [(E X_i X_i')^{-1} + o_p(1)] [\Omega + o_p(1)] [(E X_i X_i')^{-1} + o_p(1)] \\ &\stackrel{\text{Por } (E X_i X_i')^{-1} \text{ y } \Omega \text{ siendo } O(1)}{=} (E X_i X_i')^{-1} \Omega (E X_i X_i')^{-1} + o_p(1) \\ &= V + o_p(1).\end{aligned}$$

4. Modelo Lineal Partitionado

Consideremos el modelo

$$y_i = \underbrace{\beta_1}_{1 \times 1} \underbrace{x_{1i}}_{1 \times 1} + \underbrace{x_{2i}'}_{k_2 \times 1} \underbrace{\beta_2}_{k_2 \times 1} + u_i, \text{ donde } \begin{array}{l} x_{1i} \rightarrow \text{var. de interés (escalar)} \text{ y} \\ x_{2i} \rightarrow \text{vars de control (vector)}. \end{array}$$

Además, tenemos que las variables son todas exógenas:

$$E \underbrace{X_i}_{k \times 1} u_i = \begin{pmatrix} E \underbrace{x_{1i}}_{1 \times 1} u_i \\ E \underbrace{x_{2i}}_{k_2 \times 1} u_i \end{pmatrix} = \underbrace{0}_{k \times 1}, \text{ donde } k = 1 + k_2.$$

Noten que mientras $E X_i X_i'$ sea de rango completo k (no multicolinealidad perfecta) la identificación de $\beta = (\beta_1, \beta_2')$ no ha cambiado.


4.1. Proyecciones

Sea $X_{n \times k}$ una matriz de rango completo k , podemos definir la proyección

$$P_X = \underbrace{X}_{n \times k} (\underbrace{X'X}_{k \times k})^{-1} \underbrace{X'}_{k \times n}$$

Lo que hace esta matriz es crear una predicción de una variable $y_{n \times 1}$ a través de OLS:

$$\hat{Y} = P_X Y = X \underbrace{(X'X)^{-1} X' Y}_{\hat{\beta}_n}$$



Tenemos que P_X proyecta vectores de tamaño $n \times 1$ a un subespacio

$$S(X) = \{y \in \mathbb{R}^n : y = Xb, b \in \mathbb{R}^k\}.$$

Además, mostraremos que es una proyección ortogonal.

Considera la diferencia

$$\begin{aligned} Y - P_X Y &= (I_n - P_X) Y \\ &= M_X Y. \end{aligned}$$

Noten que

$$M_X Y = Y - \hat{Y} = Y - X\hat{\beta} = \hat{U}. \rightarrow \text{genera residuos de OLS.}$$

Por ello, decimos que es una proyección ortogonal

$$Y = P_X Y + M_X Y = \hat{Y} + \hat{U},$$

donde

$$\hat{Y}'\hat{U} = Y'X(X'X)^{-1}X'\hat{U} = 0.$$

⊗ Es decir, OLS descompone Y en dos vectores ortogonales entre sí.

Proposición:-

- (a) P_X y M_X son simétricas: $P_X = P_X'$, $M_X = M_X'$.
- (b) $P_X X = X \rightarrow X$ ya pertenece a ese subespacio
- (c) $M_X X = 0 \rightarrow$ consecuencia de lo anterior
- (d) P_X y M_X son ortogonales: $M_X P_X = 0$ y $P_X M_X = 0$
- (e) P_X y M_X son idempotentes: $P_X P_X = P_X$ y $M_X M_X = M_X$
- (f) $\text{rank}(P_X) = k$ y $\text{rank}(M_X) = n - k$.

Proposición.- La suma de residuos al cuadrado **SSR** no puede decrecer a medida que aumentamos regresores.

Proof:

Consideren $X = (X_1 \ X_2)$. Tenemos

$$P_X = X(X'X)^{-1}X' \rightarrow M_X = I_n - P_X.$$

$$P_1 = X_1(X_1'X_1)^{-1}X_1' \rightarrow M_1 = I_n - P_1.$$

Además, ya que X_1 es parte de X se cumple que $P_X X_1 = X_1$.

Por lo tanto,

$$\begin{aligned} P_X P_1 &= P_X X_1 (X_1'X_1)^{-1}X_1' \\ &= X_1 (X_1'X_1)^{-1}X_1' \\ &= P_1. \end{aligned}$$

$$\begin{aligned} M_X M_1 &= (I_n - P_X)(I_n - P_1) \\ &= I_n - P_1 - P_X + P_X P_1 \\ &= I_n - P_1 - P_X + P_1 \\ &= I_n - P_X \\ &= M_X. \end{aligned}$$

Definiremos ahora

$$\hat{U}_X = M_X Y,$$

$$\hat{U}_{X_1} = M_1 Y,$$

y escribimos

$$\begin{aligned} 0 &\leq (\hat{U}_X - \hat{U}_{X_1})'(\hat{U}_X - \hat{U}_{X_1}) \rightarrow \|\hat{U}_X - \hat{U}_{X_1}\|^2 \geq 0 \\ &= \hat{U}_X' \hat{U}_X + \hat{U}_{X_1}' \hat{U}_{X_1} - 2 \hat{U}_X' \hat{U}_{X_1} \\ &= \hat{U}_X' \hat{U}_X + \hat{U}_{X_1}' \hat{U}_{X_1} - 2 Y' M_X M_1 Y \\ &= \hat{U}_X' \hat{U}_X + \hat{U}_{X_1}' \hat{U}_{X_1} - 2 Y' M_X Y \\ &= \hat{U}_X' \hat{U}_X + \hat{U}_{X_1}' \hat{U}_{X_1} - 2 \hat{U}_X' \hat{U}_X \\ &= \hat{U}_{X_1}' \hat{U}_{X_1} - \hat{U}_X' \hat{U}_X \end{aligned}$$

Por lo tanto,

$$\underbrace{\hat{U}_{X_1}' \hat{U}_{X_1}}_{\text{Suma de residuos con } X_1} \geq \underbrace{\hat{U}_X' \hat{U}_X}_{\text{Suma de residuos con } X_1, X_2}.$$

4.2. Regresión Portionada (Cont.)

Sea $X = (X_1 \ X_2)$, tenemos:

$$X'X = \begin{pmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{pmatrix}$$

$K \times K$

Además, $\hat{\beta}_n$ satisface la condición de primer orden

$$X'X \hat{\beta}_n = X'Y$$

$$\Rightarrow \begin{pmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{pmatrix} \begin{pmatrix} \hat{\beta}_{1n} \\ \hat{\beta}_{2n} \end{pmatrix} = \begin{pmatrix} X_1' \\ X_2' \end{pmatrix} Y$$

$K \times K$ $K \times n$

$$\Rightarrow \begin{aligned} X_1'X_1 \hat{\beta}_{1n} + X_1'X_2 \hat{\beta}_{2n} &= X_1'Y & (1) \\ X_2'X_1 \hat{\beta}_{1n} + X_2'X_2 \hat{\beta}_{2n} &= X_2'Y & (2) \end{aligned}$$

Si $X_2'X_2$ es invertible, podemos despejar de (2):

$$\hat{\beta}_{2n} = (X_2'X_2)^{-1} X_2'Y - (X_2'X_2)^{-1} X_2'X_1 \hat{\beta}_{1n} \quad (3)$$

Reemplazando (3) en (1), nuevamente suponiendo $X_1'X_1$ es invertible:

$$X_1'X_1 \hat{\beta}_{1n} + X_1'X_2 [(X_2'X_2)^{-1} X_2'Y - (X_2'X_2)^{-1} X_2'X_1 \hat{\beta}_{1n}] = X_1'Y$$

$$\Rightarrow [X_1'X_1 - X_1'X_2 (X_2'X_2)^{-1} X_2'X_1] \hat{\beta}_{1n} = X_1'Y - X_1'X_2 (X_2'X_2)^{-1} X_2'Y$$

$$\Rightarrow X_1' (I_n - X_2 (X_2'X_2)^{-1} X_2') X_1 \hat{\beta}_{1n} = X_1' (I_n - X_2 (X_2'X_2)^{-1} X_2') Y$$

$$\Rightarrow X_1' M_2 X_1 \hat{\beta}_{1n} = X_1' M_2 Y$$

$$\Rightarrow \hat{\beta}_{1n} = (X_1' M_2 X_1)^{-1} X_1' M_2 Y.$$

Además, noten que $\hat{\beta}_{1n} = (\tilde{X}_1' \tilde{X}_1)^{-1} \tilde{X}_1' \tilde{Y}$, donde $\tilde{X}_1 = M_2 X_1$ e $\tilde{Y} = M_2 Y$.

⊕ Es decir, equivale a hacer una regresión de X_1 sobre X_2 y de Y sobre X_2 para luego hacer una regresión entre ambos residuos. Este resultado se conoce como el Teorema de Frisch-Waugh-Lovell.

⊗ Podemos pensar en $\tilde{X}_{1i} = X_{1i} - X_{2i}' \hat{\gamma}$, donde $\hat{\gamma} = (X_2'X_2)^{-1} X_2'X_1$.

4.2.1. Consistencia

Definimos $\sum_{A,B} := E A_i B_i'$, donde A_i, B_i son vectores aleatorios.

Tenemos

$$\begin{aligned}\hat{\beta}_{in} &= (X_1' M_2 X_1)^{-1} X_1' M_2 Y \\ &= \beta_1 + (X_1' M_2 X_1)^{-1} X_1' M_2 U,\end{aligned}$$

donde

$$\begin{aligned}\bullet \quad \frac{X_1' M_2 U}{n} &= \frac{X_1' (I_n - X_2 (X_2' X_2)^{-1} X_2') U}{n} \\ &= \frac{X_1' U}{n} - \underbrace{\frac{X_1' X_2}{n}}_{=0} \underbrace{(X_2' X_2)^{-1}}_{=0} \frac{X_2' U}{n} \\ &= \sum_{i=1}^n x_{1i} u_i / n - \sum_{i=1}^n \frac{x_{1i} x_{2i}'}{n} \left(\sum_{i=1}^n \frac{x_{2i} x_{2i}'}{n} \right)^{-1} \sum_{i=1}^n \frac{x_{2i} u_i}{n} \\ \text{WLLN} &= \underbrace{\sum_{x_1, u}}_{=0} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \underbrace{\sum_{x_2, u}}_{=0} + o_p(1) \\ &= o_p(1)\end{aligned}$$

$$\begin{aligned}\bullet \quad \frac{X_1' M_2 X_1}{n} &= \frac{X_1' X_1}{n} - \frac{X_1' P_2 X_1}{n} \\ &= \underbrace{\sum_{x_1, x_1}}_{\neq 0 \text{ (no singular)}} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, x_1} + o_p(1)\end{aligned}$$

Solo se cancela si $x_1 = x_2$, lo cual no tendría sentido. Como no es singular, su inversa es $O(1)$

Entonces,

$$\begin{aligned}\hat{\beta}_{in} &= \beta_1 + (X_1' M_2 X_1)^{-1} X_1' M_2 U \\ &= \beta_1 + \left(\sum_{x_1, x_1} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, x_1} + o_p(1) \right)^{-1} o_p(1) \\ &= \beta_1 + (O(1) + o_p(1)) o_p(1) \\ &= \beta_1 + o_p(1).\end{aligned}$$

¿Qué pasa si el vector de controles X_{2i} fuera **endógeno**? A esto le llamamos **Bod Controls**.

Supongamos que ahora X_{2i} es endógeno : $E X_{2i} u_i \neq 0$.

$$\begin{aligned}\hat{\beta}_{1n} &= (X_1' M_2 X_1)^{-1} X_1' M_2 Y \\ &= \beta_1 + (X_1' M_2 X_1)^{-1} X_1' M_2 U,\end{aligned}$$

donde

$$\begin{aligned}\bullet \quad \frac{X_1' M_2 U}{n} &= X_1' (I_n - X_2 (X_2' X_2)^{-1} X_2') U / n \\ &= X_1' U / n - \underbrace{X_1' X_2}_{\frac{1}{n}} \underbrace{(X_2' X_2)^{-1}}_{\frac{1}{n}} X_2' U / n \\ &= \sum_{i=1}^n x_{1i} u_i / n - \sum_{i=1}^n \frac{x_{1i} x_{2i}'}{n} \left(\sum_{i=1}^n \frac{x_{2i} x_{2i}'}{n} \right)^{-1} \sum_{i=1}^n \frac{x_{2i} u_i}{n} \\ \text{WLLN} &= \underbrace{\sum_{x_1, u}}_{=0} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \underbrace{\sum_{x_2, u}}_{\text{Ahora } \neq 0 \text{ (endógeno)}} + o_p(1) \\ &= o_p(1)\end{aligned}$$

$$\begin{aligned}\bullet \quad \frac{X_1' M_2 X_1}{n} &= \frac{X_1' X_1}{n} - \frac{X_1' P_2 X_1}{n} \\ &= \underbrace{\sum_{x_1, x_1}}_{\neq 0 \text{ (no singular)}} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, x_1} + o_p(1)\end{aligned}$$

Solo se cancela si $x_1 = x_2$, lo cual no tendría sentido. Como no es singular, su inversa es $O(1)$

Entonces,

$$\begin{aligned}\hat{\beta}_{1n} &= \beta_1 + \left(\sum_{x_1, x_1} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, x_1} + o_p(1) \right)^{-1} \left(- \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, u} + o_p(1) \right) \\ &= \beta_1 - \left[\sum_{x_1, x_1} - \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, x_1} \right]^{-1} \sum_{x_1, x_2} \sum_{x_2, x_2}^{-1} \sum_{x_2, u} + o_p(1).\end{aligned}$$

~~β_1~~ β_1 ,

a menos que $\sum_{x_1, x_2} := E x_{1i} x_{2i}' = 0$, que significa que x_{1i} y x_{2i} no están correlacionados.

4.2.2 Normalidad Asintótica

$$\hat{\beta}_{in} = \beta_1 + \underbrace{(X_1' M_2 X_1)^{-1}}_n \underbrace{X_1' M_2 u}_n$$

$$\Rightarrow \sqrt{n} (\hat{\beta}_{in} - \beta_1) = \underbrace{(X_1' M_2 X_1)^{-1}}_n \underbrace{X_1' M_2 u}_{\sqrt{n}}$$

$$= \left[(\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}') + o_p(1) \right] \left[\frac{X_1' u}{\sqrt{n}} - \frac{X_1' x_2}{n} \frac{(X_2' x_2)^{-1}}{n} \frac{X_2' u}{\sqrt{n}} \right]$$

$$= \underbrace{\begin{bmatrix} (\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} & \vdots & -(\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \\ \vdots & & \vdots \end{bmatrix}}_{Q: K_1 \times (K_1 + K_2) = K_1 \times K} \begin{bmatrix} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_{1i} u_i \\ \frac{1}{\sqrt{n}} \sum_{i=1}^n x_{2i} u_i \end{bmatrix} + o_p(1)$$

Noten que nada nos impide seguir usando el CLT

$$\begin{pmatrix} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_{1i} u_i \\ \frac{1}{\sqrt{n}} \sum_{i=1}^n x_{2i} u_i \end{pmatrix} \xrightarrow{d} N \left(0, \underbrace{\begin{pmatrix} E u_i^2 x_{1i} x_{1i}' & E u_i^2 x_{1i} x_{2i}' \\ E u_i^2 x_{2i} x_{1i}' & E u_i^2 x_{2i} x_{2i}' \end{pmatrix}}_{Q: K \times K} \right),$$

siempre que la data sea iid y todos los bloques de esa varianza sean finitos $O(1)$.

Podemos mostrar que

$$\sqrt{n} (\hat{\beta}_{in} - \beta_1) \xrightarrow{d} N(0, Q \Omega Q'),$$

donde

$$Q \Omega Q' = \begin{bmatrix} (\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} E u_i^2 x_{1i} x_{1i}' & \vdots & -(\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} E u_i^2 x_{2i} x_{2i}' \\ \vdots & & \vdots \end{bmatrix} Q'$$

$$= (\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} E u_i^2 x_{1i} x_{1i}' (\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} +$$

$$(\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1} \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} E u_i^2 x_{2i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{1i} x_{2i}' (\sum_{i=1}^n x_{1i} x_{1i}' - \sum_{i=1}^n x_{1i} x_{2i}' \sum_{i=1}^n x_{2i} x_{2i}^{-1} \sum_{i=1}^n x_{2i} x_{1i}')^{-1}.$$

En el caso homoscedástico $E[u_i^2 | x_{1i}, x_{2i}] = \sigma^2$. Por tanto

$$\begin{aligned} \bullet \quad E[u_i^2 x_{1i} x_{1i}'] &= E[E[u_i^2 | x_{1i}] x_{1i} x_{1i}'] \\ &\quad \text{L.I.E.} \\ &= \sigma^2 E[x_{1i} x_{1i}'] \end{aligned}$$

$$\begin{aligned} \bullet \quad E[u_i^2 x_{2i} x_{2i}'] &= E[E[u_i^2 | x_{1i}] x_{2i} x_{2i}'] \\ &\quad \text{L.I.E.} \\ &= \sigma^2 E[x_{2i} x_{2i}'] \end{aligned}$$

Por lo tanto, $Q'Q$ se reduce a

$$\begin{aligned} Q'Q &= (\sum x_{1i} x_{1i} - \sum x_{1i} x_{2i} \sum x_{2i} x_{2i}^{-1} \sum x_{2i} x_{1i})' \sigma^2 [\sum x_{1i} x_{1i} - \sum x_{1i} x_{2i} \sum x_{2i} x_{2i}^{-1} \sum x_{2i} x_{1i}] (\sum x_{1i} x_{1i} - \sum x_{1i} x_{2i} \sum x_{2i} x_{2i}^{-1} \sum x_{2i} x_{1i})' \\ &= \sigma^2 \underbrace{(\sum x_{1i} x_{1i} - \sum x_{1i} x_{2i} \sum x_{2i} x_{2i}^{-1} \sum x_{2i} x_{1i})'}_{\text{varianza de } x_1 \text{ una vez}} \end{aligned}$$

que hemos quitado la
porción explicada por x_2 .

⊛ A medida que añadimos regresores a x_2 hacemos dos

cosas:

↓ σ : varianza de Y no explicada

↓ $(\sum x_{1i} x_{1i} - \sum x_{1i} x_{2i} \sum x_{2i} x_{2i}^{-1} \sum x_{2i} x_{1i})$: varianza residual de x_1 no explicada por x_2

Si aumentamos indiscriminadamente regresores es probable que la segunda fuerza termine dominando y causara errores estándar altos $\hat{\text{var}}(\beta_1) \uparrow$. Esto causará valores t bajos y p -valores altos (no significancia estadística).

5. Inferencia

Por simplicidad consideremos

$$Y_i = x_{1i} \beta_1 + x_{2i}' \beta_2 + u_i, \quad E(u_i | x_{1i}) = 0, \quad E(u_i | x_{2i}) = 0$$

$\downarrow$ 1×1 $\downarrow$ $k \times k_2$
 Regresor de interés Controles

Como ya determinamos anteriormente

$$\hat{\beta}_1 = \frac{x_1' M_2 Y}{\underbrace{x_1' M_2 x_1}_{\text{ahora esto es } 1 \times 1}} = \beta_1 + \frac{x_1' M_2 u}{x_1' M_2 x_1}$$

Además, hemos mostrado el siguiente resultado:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} N(0, V)$$

$\sqrt{n} \begin{pmatrix} \hat{\beta}_1 - \beta_1 \\ \hat{\beta}_2 - \beta_2 \end{pmatrix} \xrightarrow{d} N \left(\begin{pmatrix} 0_{1 \times 1} \\ 0_{k_2 \times 1} \end{pmatrix}, \begin{pmatrix} V_{11} & 0 \\ 0 & V_2 \end{pmatrix} \right)$

Es decir,

$$\sqrt{n}(\hat{\beta}_1 - \beta_1) \xrightarrow{d} N(0, V_{11}). \quad \textcircled{1}$$

Para simplificar el álgebra nos centraremos en el caso homoscedástico $E(u_i^2 | x_i) = \sigma^2$.
En ese caso:

$$V_{11} = \frac{\sigma^2}{\sum x_{1i} x_{1i} - \sum x_{1i} x_{2i} \sum x_{2i} x_{2i}^{-1} \sum x_{2i} x_{1i}}$$

su estimador $\rightarrow$

$$\hat{V}_{11} = \frac{\hat{\sigma}^2}{\frac{x_1' M_2 x_1}{n}}, \quad \text{donde} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - x_i' \hat{\beta})^2.$$

Noten, además que $\textcircled{1}$ implica $\hat{\beta}_1 \sim N(\beta_1, \underbrace{V_{11}/n}_{\sqrt{\frac{\hat{V}_{11}}{n}} := \text{SE}(\hat{\beta}_1) \text{ error estándar}})$.

Por lo tanto podemos plantear el siguiente intervalo de confianza al nivel $1-\alpha$:

$$CI_{1-\alpha} = \left[\hat{\beta}_1 - z_{1-\alpha/2} \sqrt{\frac{\hat{V}_{11}}{n}}, \hat{\beta}_1 + z_{1-\alpha/2} \sqrt{\frac{\hat{V}_{11}}{n}} \right].$$

Consideren el test

$$H_0: \beta_1 = \beta_{1,0},$$

$$H_1: \beta_1 \neq \beta_{1,0},$$

usaré subíndice 0 para referir al valor testeable.

donde rechazamos H_0 si

$$\hat{\beta}_1 \notin CI_{1-\alpha}.$$

Es decir, la región crítica es el complemento del $CI_{1-\alpha}$. Este es equivalente a rechazar si

$$\beta_{1,0} < \hat{\beta}_1 - z_{1-\alpha/2} \sqrt{\frac{\hat{V}_{11}}{n}}$$

o

$$\beta_{1,0} > \hat{\beta}_1 + z_{1-\alpha/2} \sqrt{\frac{\hat{V}_{11}}{n}}.$$

Esto puede re-escribirse como algo que probablemente recuerden

$$T_n := \left| \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\hat{V}_{11}/n}} \right| > z_{1-\alpha/2},$$

test estadístico

que es lo que conocemos como **two sided test**, porque si se cumple H_1 el valor del verdadero β_1 puede ser menor o mayor a $\beta_{1,0}$.

5.1. Test de Tamaño α

Decimos que el test es (asintóticamente) de tamaño α si

$$\lim_{n \rightarrow \infty} P(\text{Rechazar } H_0 \mid H_0 \text{ es verdadero}) \rightarrow \alpha.$$

En este caso tenemos que

$$\begin{aligned} P(\text{Rechazar } H_0 \mid H_0 \text{ es verdadero}) &= P\left(\left| \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\hat{V}_{11}/n}} \right| > z_{1-\alpha/2} \mid \beta_1 = \beta_{1,0} \right) \\ &= P\left(\left| \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\hat{V}_{11}/n}} \right| > z_{1-\alpha/2} \right) \end{aligned}$$


Tomando límite tenemos

$$\lim_{n \rightarrow \infty} P\left(\left| \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\hat{V}_{11}/n}} \right| > z_{1-\alpha/2} \right) = \alpha.$$


5.2 P-values

Recuerden que rechazamos si:

$$\overset{\substack{\text{test} \\ \text{estadístico}}}{T_n} := \left| \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\hat{V}_{11}/n}} \right| > z_{1-\alpha/2}$$




Si T_n cae debajo de $z_{1-\alpha/2}$ NO podemos rechazar.




Si T_n cae encima de $z_{1-\alpha/2}$ SÍ podemos rechazar.

Así como comparamos T_n contra $z_{1-\alpha/2}$ es EQUIVALENTE a comparar el área a la derecha de T_n con el área a la derecha de $z_{1-\alpha/2}$.



Si el área por encima de T_n es mayor al área por encima de $z_{1-\alpha/2}$ no podemos rechazar.



Si el área por encima de T_n es menor al área por encima de $z_{1-\alpha/2}$ no podemos rechazar.

De hecho, podemos calcular estos números. Rechazamos si

$$\text{Area encima de } T_n < \text{Area encima de } T_n$$

$$1 - \Phi(T_n) < 1 - \Phi(Z_{1-\alpha/2}) = \alpha/2, \text{ donde } \Phi(\cdot) \text{ es el CDF de } N(0,1).$$

Podemos multiplicar ambos lados por 2 y no afectar la desigualdad:

$$2(1 - \Phi(T_n)) < \alpha.$$

A este número
le llamamos
p-value.

En otras palabras, el p-value es una función del estadístico T_n así que es un estadístico: NO es la probabilidad de que H_0 es cierta.

De aquí viene nuestra regla usual de rechazar con $\alpha=0.05$ si:

$$p\text{-val} < 0.05 \quad \text{o, equivalentemente,} \quad T_n := \left| \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\hat{V}_{11}/n}} \right| > 1.96.$$

5.3. Poder Asintótico del Test

Cuando H_0 es falsa, queremos que nuestro test rechace correctamente. A esto le llamamos poder estadístico.

$$\begin{aligned} P(\text{rechazar } H_0 \mid \beta_1 \neq \beta_{1,0}) &= P\left(\left| \frac{\hat{\beta}_1 - \beta_{1,0} \pm \beta_1}{\sqrt{\hat{V}_{11}/n}} \right| > Z_{1-\alpha/2}\right) \\ &= P\left(\left| \underbrace{\frac{\hat{\beta}_1 - \beta_1}{\sqrt{\hat{V}_{11}/n}}}_{\xrightarrow{d} N(0,1)} + \underbrace{\frac{\beta_1 - \beta_{1,0}}{\sqrt{\hat{V}_{11}/n}}}_{\xrightarrow{p} \pm\infty} \right| > Z_{1-\alpha/2}\right) \end{aligned}$$

Entonces,

$$\lim_{n \rightarrow \infty} P(\text{rechazar } H_0 \mid \beta_1 \neq \beta_{1,0}) = 1.$$

* El test promete que con una muestra grande siempre rechazaremos si H_0 es falsa.