

Formulación matricial del modelo lineal general

Estimadores MCO usando matrices

Mariana Marchionni
marchionni.mariana@gmail.com

Econometría I - FCE - UNLP
www.econometria1unlp.com

Temario de la clase

- 1 El modelo en notación matricial
- 2 Repaso de álgebra matricial
 - Algunas definiciones y resultados
 - Derivadas matriciales
- 3 Los estimadores MCO
 - MCO usando matrices
 - Propiedades algebraicas en notación matricial
 - R cuadrado y R cuadrado ajustado
- 4 Supuestos clásicos y propiedades
 - Supuestos clásicos en notación matricial
 - Propiedades estadísticas en notación matricial

El modelo lineal con K variables

- Vimos el modelo

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \cdots + \beta_K X_{Ki} + u_i, \quad i = 1, \dots, n$$

- Como vale para $i = 1, \dots, n$, entonces podemos escribir:

$$Y_1 = \beta_1 + \beta_2 X_{21} + \beta_3 X_{31} + \cdots + \beta_K X_{K1} + u_1$$

$$Y_2 = \beta_1 + \beta_2 X_{22} + \beta_3 X_{32} + \cdots + \beta_K X_{K2} + u_2$$

\vdots

$$Y_n = \beta_1 + \beta_2 X_{2n} + \beta_3 X_{3n} + \cdots + \beta_K X_{Kn} + u_n$$

- Sistema de n ecuaciones lineales. ¿Lineales en qué?
- Todo sistema lineal puede ser expresado en matrices

Formulación matricial del modelo

- Notar que el modelo puede escribirse como:

$$Y = X\beta + u$$
$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{21} & X_{31} & \cdots & X_{K1} \\ 1 & X_{22} & X_{32} & \cdots & X_{K2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{2n} & X_{3n} & \cdots & X_{Kn} \end{bmatrix} \cdot \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

- ¿Qué dimensiones tiene cada matriz/vector?

$$X = \begin{bmatrix} 1 & X_{21} & X_{31} & \cdots & X_{K1} \\ 1 & X_{22} & X_{32} & \cdots & X_{K2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{2n} & X_{3n} & \cdots & X_{Kn} \end{bmatrix}$$

X es $(n \times K)$, n filas (observaciones) y K columnas (variables explicativas)

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

Y y u son $(n \times 1)$, y β es $(K \times 1)$.

- Entonces, el modelo

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \cdots + \beta_K X_{Ki} + u_i, \quad i = 1, \dots, n$$

- Puede escribirse como

$$Y = X\beta + u$$

- **Este es el modelo lineal general (K variables) expresado en notación matricial**
 - Ventaja: nos permitirá trabajar expresiones sin el uso de sumatorias
 - Desventaja: trabajar con álgebra matricial puede ser un poco molesto al principio

Digresión: definiciones y resultados de álgebra matricial

- **Rango de una matriz.** Def.: es el número máximo de filas y/o columnas linealmente independientes (li). Lo denotamos como $\rho(X)$
- Resultado 1: el **máximo nro. de columnas li = máximo nro. de filas li**. En otras palabras: el rango columna coincide con el rango fila.
- **Matriz no singular.** Def.: una matriz cuadrada $A_{(K \times K)}$ es no singular, si y solo si su determinante es distinto de cero, es decir, $|A| \neq 0$.
- Resultado 2: si la matriz $A_{(K \times K)}$ es no singular \Rightarrow existe una única matriz, también no singular, a la que llamamos **inversa de A** y denotamos como A^{-1} , tal que $AA^{-1} = A^{-1}A = I_K$
- Resultado 3. Sea una matriz $A_{(K \times K)}$:
$$\begin{cases} \rho(A) = K & \implies |A| \neq 0 \\ \rho(A) < K & \implies |A| = 0 \end{cases}$$
- Resultado 4. Sea una matriz $X_{(n \times K)}$ con $\rho(X) = K$ (rango columna completo). Se cumple que $\rho(X) = \rho(X'X) = K$

¿Qué es $X'X$ en nuestro modelo?

Supongamos $n = 3$ y $K = 2$:

$$X = \begin{bmatrix} 1 & X_{21} \\ 1 & X_{22} \\ 1 & X_{23} \end{bmatrix} \Rightarrow X'X = \begin{bmatrix} 3 & X_{21} + X_{22} + X_{23} \\ X_{21} + X_{22} + X_{23} & X_{21}^2 + X_{22}^2 + X_{23}^2 \end{bmatrix}$$

Generalizando para cualquier n y K :

$$X'X = \begin{bmatrix} n & \sum X_{2i} & \sum X_{3i} & \cdots & \sum X_{Ki} \\ \sum X_{2i} & \sum X_{2i}^2 & \sum X_{2i}X_{3i} & \cdots & \sum X_{2i}X_{Ki} \\ \sum X_{3i} & \sum X_{2i}X_{3i} & \sum X_{3i}^2 & \cdots & \sum X_{3i}X_{Ki} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum X_{Ki} & \sum X_{2i}X_{Ki} & \sum X_{3i}X_{Ki} & \cdots & \sum X_{Ki}^2 \end{bmatrix}$$

- notar que $X'X$ es de dimensión $(K \times K)$

¿Qué nos dice el resultado 4?

- Recordemos el resultado 4: Si $\rho(X) = K$ (rango columna completo), se cumple que $\rho(X) = \rho(X'X) = K$
- ¿Qué se requiere para que $\rho(X) = K$?

$$X = \begin{bmatrix} 1 & X_{21} & X_{31} & \cdots & X_{K1} \\ 1 & X_{22} & X_{32} & \cdots & X_{K2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{2n} & X_{3n} & \cdots & X_{Kn} \end{bmatrix}$$

- Por el resultado 4 sabemos que si $\rho(X) = K$ entonces $\rho(X'X) = K$. En otras palabras, que $\rho(X) = K$ garantiza que $X'X$ tiene rango completo y por lo tanto es una matriz no singular (resultado 3), lo que implica que $\exists (X'X)^{-1}$ (resultado 2).
 - Que $X'X$ tenga inversa es muy importante, ya veremos...

Digresión: derivación con matrices

- **Regla 1:** sean a y b dos vectores ($K \times 1$), entonces:

$$\frac{\partial(b'a)}{\partial b} = a$$

- **Regla 2:** sea A una matriz simétrica ($K \times K$) y b un vector ($K \times 1$), entonces:

$$\frac{\partial(b'Ab)}{\partial b} = 2Ab$$

Chequeamos la regla 1: $\frac{\partial(b'a)}{\partial b} = a$

Supongamos $K = 2$: $a = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}$ y $b = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix}$

- Notar que $b'a = b_1 a_1 + b_2 a_2$ es un escalar (dimensión 1×1)

$\Rightarrow \frac{\partial(b'a)}{\partial b}$ es un escalar derivado por un vector. ¿Y eso?

- Derivar por un vector ($K \times 1$) es derivar por cada uno de los K elementos del vector.
 - Derivamos $b'a = b_1 a_1 + b_2 a_2$ primero respecto de b_1 y obtenemos a_1 ; después derivamos respecto de b_2 y obtenemos a_2 . Luego “apilamos” los resultados en un nuevo vector (vector de derivadas):

$$\frac{\partial(b'a)}{\partial b} = \begin{bmatrix} \frac{\partial(b'a)}{\partial b_1} \\ \frac{\partial(b'a)}{\partial b_2} \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = a$$

Chequeamos la regla 2: $\frac{\partial(b'Ab)}{\partial b} = 2Ab$

Supongamos otra vez $K = 2$: $b = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix}$ y $A = \begin{bmatrix} A_{11} & A_{12} \\ A_{12} & A_{22} \end{bmatrix}$

- Notar que $b'Ab = b_1^2 A_{11} + b_2^2 A_{22} + 2b_1 b_2 A_{12}$ es una función cuadrática en b (y es un escalar)
- Entonces, ¿qué es $\frac{\partial(b'Ab)}{\partial b}$?
- Derivamos:

$$\frac{\partial(b'Ab)}{\partial b} = \begin{bmatrix} \frac{\partial(b'Ab)}{\partial b_1} \\ \frac{\partial(b'Ab)}{\partial b_2} \end{bmatrix} = \begin{bmatrix} 2b_1 A_{11} + 2b_2 A_{12} \\ 2b_2 A_{22} + 2b_1 A_{12} \end{bmatrix} = 2Ab$$

MCO en matrices

Recordemos la formulación matricial del modelo lineal general:

$$Y = X\beta + u$$

- Sea $\hat{\beta}$ el vector que apila los estimadores del vector de parámetros

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_K \end{bmatrix}$$

Definiciones

- Vector de estimaciones de Y ($n \times 1$):
 $\hat{Y} \equiv X\hat{\beta}$
- Vector de residuos o errores de estimación ($n \times 1$):
 $e \equiv Y - \hat{Y} = Y - X\hat{\beta}$

Recordemos la función de pérdida del método de MCO y veamos cómo escribirla con la nueva notación matricial:

$$SRC \equiv \sum_{i=1}^n e_i^2 = \begin{bmatrix} e_1 & e_2 & \cdots & e_n \end{bmatrix} \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}$$

- Es decir, la suma de residuos cuadráticos se puede reescribir como:

$$SRC \equiv e'e$$

- Recordando que $e \equiv Y - X\hat{\beta}$ es fácil ver que SRC es una función de $\hat{\beta}$:

$$SRC(\hat{\beta}) \equiv (Y - X\hat{\beta})'(Y - X\hat{\beta})$$

El problema de MCO:

$$\underset{\hat{\beta}}{\text{Min}} \text{SRC}(\hat{\beta}) \equiv e'e = (Y - X\hat{\beta})'(Y - X\hat{\beta})$$

- Notar que la función a minimizar es escalar (1×1)
- Hay que derivar esa expresión (1×1) respecto del vector $\hat{\beta}$
- Las CPO igualan el vector de derivadas al vector cero:

$$\frac{\partial \text{SRC}(\hat{\beta})}{\partial \hat{\beta}} = 0$$

- Sistema de K ecuaciones con K incógnitas

Obtención de los estimadores MCO

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

- En el último paso, notar que los términos 2do y 3ro son iguales porque (1) ambos son escalares, (2) si trasponemos $(Y'X\hat{\beta})$ obtenemos $(\hat{\beta}'X'Y)$ y viceversa, y (3) un escalar traspuesto siempre es igual al mismo escalar.
- Ahora hay que derivar respecto del vector $\hat{\beta}$
 - El primer término no depende de $\hat{\beta}$
 - Notar que el 2do término es de la forma $b'a$, con $b = \hat{\beta}$ y $a = X'Y$ (recordar regla 1)
 - Notar que el 3er término es de la forma $b'Ab$, con $b = \hat{\beta}$ y $A = X'X$ (recordar regla 2)

- La función a minimizar:

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

- Las CPO:

$$\frac{\partial e'e}{\partial \hat{\beta}} = 0 - 2X'Y + 2X'X\hat{\beta} = 0 \Rightarrow X'X\hat{\beta} = X'Y$$

- Si existe $(X'X)^{-1}$, entonces:

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

- $\hat{\beta}$ es el vector de estimadores MCO

¿De qué depende que exista $(X'X)^{-1}$?

- Vimos antes (resultado 4) que si $\rho(X) = K$ (rango columna completo), entonces $\exists (X'X)^{-1}$
- El supuesto de no multicolinealidad perfecta justamente dice que $\rho(X) = K$
- **La ausencia de multicolinealidad perfecta es necesaria para que exista el vector de estimadores MCO**

Propiedades algebraicas en notación matricial

Propiedad 1: los estimadores de MCO son lineales, es decir tienen la forma

$$\hat{\beta} = AY$$

donde A es una matriz ($K \times n$) con elementos *no estocásticos* (no aleatorios).

Prueba:

- Los estimadores MCO son $\hat{\beta} = (X'X)^{-1}X'Y$
- Si llamamos A a la matriz $(X'X)^{-1}X'$ (de dimensión $K \times n$), $\hat{\beta}$ queda escrito en la forma lineal

Propiedad 2: $X'e = 0$

- Puede obtenerse a partir de la CPO: $X'X\hat{\beta} = X'Y$
- Mostrar que esta propiedad implica 2 resultados que ya vimos antes:

$$\textcircled{1} \sum_{i=1}^n e_i = 0$$

$$\textcircled{2} \sum_{i=1}^n X_{ki}e_i = 0 \quad k = 2, \dots, K$$

- ¿Qué nos dicen estos resultados intuitivamente?

Propiedad 3: similar a la propiedad anterior:

$$\hat{Y}'e = 0$$

Propiedad 4: el punto (\bar{X}, \bar{Y}) pertenece a la función de regresión estimada por MCO:

$$\bar{Y} = \bar{X}\hat{\beta}$$

Bondad del ajuste usando notación matricial

La descomposición de la suma de cuadrados es

$$\begin{aligned} \sum_{i=1}^N (Y_i - \bar{Y})^2 &= \sum_{i=1}^N (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^N e_i^2 \\ \underbrace{Y'Y - n\bar{Y}^2}_{STC} &= \underbrace{\hat{Y}'\hat{Y} - n\bar{Y}^2}_{SEC} + \underbrace{e'e}_{SRC} \end{aligned}$$

Entonces, la bondad del ajuste puede escribirse como:

$$R^2 = \frac{\hat{Y}'\hat{Y} - n\bar{Y}^2}{Y'Y - n\bar{Y}^2} = 1 - \frac{e'e}{Y'Y - n\bar{Y}^2}$$

R^2 no decrece con K

- El R^2 nunca decrece con el agregado de variables explicativas
- En general, cuantas más variables mayor será el R^2
- El R^2 tiende a aumentar aunque las variables que agregamos no sean estadísticamente significativas
- Entonces, trivialmente, a mayor número de variables mejor ajusta el modelo. ¿Por qué?

R^2 no decrece con K

- Suponer el modelo $Y = X\beta + Z\gamma + u$
 X matriz $n \times K_1$ (incluye constante), Z matriz $n \times K_2$, con $K = K_1 + K_2$
- **Problema 1:** regresión de Y en X y Z .
$$\underset{\hat{\beta}, \hat{\gamma}}{\text{Min}} \text{SRC}(\hat{\beta}, \hat{\gamma}) = (Y - X\hat{\beta} - Z\hat{\gamma})'(Y - X\hat{\beta} - Z\hat{\gamma}) \rightarrow \text{SRC}_1^*$$
- **Problema 2:** regresión de Y en X solamente
igual al problema 1 pero le agregamos una restricción: s.a
 $\hat{\gamma} = 0 \rightarrow \text{SRC}_2^*$
- Siempre $\text{SRC}_1^* \leq \text{SRC}_2^* \Rightarrow R_1^2 \geq R_2^2$
con desigualdad estricta si $\hat{\gamma} \neq 0$

R^2 no decrece con K

- Pensemos en que tenemos un modelo y agregamos una nueva variable. El R^2 aumenta siempre que el coeficiente de regresión estimado de la nueva variable tenga un valor distinto de cero.
- Numéricamente distinto de cero \neq estadísticamente distinto de cero.
- Implicancia: no tiene sentido basarse en el R^2 para comparar el ajuste de modelos con distinta cantidad de variables.
- ¿Entonces?

R^2 ajustado

$$R^2 \text{ ajustado} = 1 - \frac{SRC}{STC} \frac{(n-1)}{(n-K)}$$

¿Qué pasa con el R^2 ajustado si agregamos una nueva variable al modelo?

- STC no cambia. ¿Por qué?
- $(n - K)$ cae en una unidad
- SRC también cae. ¿Cuánto? Depende...
 - Cuanto más relevante sea la nueva variable, más cae SRC . ¿Por qué?
 - Entonces, cuanto más relevante sea la nueva variable, más aumenta R^2 ajustado.
 - Si la variable es poco relevante, R^2 ajustado puede caer

R^2 ajustado

$$R^2 \text{ ajustado} = 1 - \frac{SRC}{STC} \frac{(n-1)}{(n-K)}$$

- **Intuición.** El $R^2 \text{ ajustado}$ incorpora el trade-off que se genera cuando agregamos más variables al modelo: por un lado baja SRC y por el otro perdemos grados de libertad, lo que implica estimadores más ineficientes.
- **En la práctica:**
 - $R^2 \text{ ajustado}$ aumenta siempre que el estadístico $|t| > 1$.
Entonces puede darse que el $R^2 \text{ ajustado}$ aumente aunque la nueva variable NO sea estadísticamente significativa.
 - $R^2 \text{ ajustado}$ baja siempre que el estadístico $|t| < 1$.

Supuestos clásicos en notación matricial

- Modelo lineal:

$$Y = X\beta + u$$

- Supuestos clásicos:

- 1 $E(u) = 0$
- 2 $VarCov(u) = \sigma^2 I_n$
- 3 X es una matriz ($n \times K$) no estocástica (no aleatoria) con $\rho(X) = K$ (rango columna completo)

Esperanza de u

- Recordemos que u es un vector aleatorio
- $E(u)$ es el vector de las esperanzas

$$u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} \implies E(u) = \begin{bmatrix} E(u_1) \\ E(u_2) \\ \vdots \\ E(u_n) \end{bmatrix}$$

- El supuesto 1 establece que el vector de esperanzas es igual al vector nulo, es decir:

$$E(u_i) = 0 \text{ para } i = 1, \dots, n$$

Matriz de varianzas y covarianzas de u

- La matriz de varianzas y covarianzas de un vector aleatorio u se define como:

$$\begin{aligned} \text{VarCov}(u) &= E[(u - E(u))(u - E(u))'] \\ &= \begin{bmatrix} V[u_1] & \text{Cov}[u_1, u_2] & \cdots & \text{Cov}[u_1, u_n] \\ \text{Cov}[u_2, u_1] & V[u_2] & \cdots & \text{Cov}[u_2, u_n] \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}[u_n, u_1] & \text{Cov}[u_n, u_2] & \cdots & V[u_n] \end{bmatrix} \end{aligned}$$

- Notar que $\text{VarCov}[u]$ es una matriz $n \times n$ y simétrica
- ¿Qué significa entonces suponer que $\text{VarCov}(u) = \sigma^2 I_n$?
- Notar: $\text{VarCov}(u) = E(uu')$

Propiedades estadísticas de los estimadores MCO

- $\hat{\beta}$ es un vector que contiene K variables aleatorias
- ¿Qué propiedades conocían en el caso de MCO con 2 variables? ¿De qué dependían?
- Vamos a demostrar esas mismas propiedades usando notación matricial

Insesgadez de $\hat{\beta}$

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1}X'Y \\ &= (X'X)^{-1}X'(X\beta + u) \\ &= (X'X)^{-1}X'X\beta + (X'X)^{-1}X'u \\ &= \beta + (X'X)^{-1}X'u \quad (*)\end{aligned}$$

$$\begin{aligned}E[\hat{\beta}] &= \beta + (X'X)^{-1}X'E[u] \\ &= \beta\end{aligned}$$

Matriz de varianzas y covarianzas de $\hat{\beta}$

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

$$\begin{aligned}\text{VarCov}[\hat{\beta}] &= E[(\hat{\beta} - E(\hat{\beta}))(\hat{\beta} - E(\hat{\beta}))'] \\ &= E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'] \\ &= E[(X'X)^{-1}X'u((X'X)^{-1}X'u)'] \\ &= E[(X'X)^{-1}X'uu'X(X'X)^{-1}] \\ &= (X'X)^{-1}X'E[uu']X(X'X)^{-1} \\ &= (X'X)^{-1}X'\sigma^2I_nX(X'X)^{-1} \\ &= \sigma^2(X'X)^{-1}X'X(X'X)^{-1} \\ &= \sigma^2(X'X)^{-1}\end{aligned}$$

- Es importante saber qué supuestos fueron utilizados para obtener esta expresión.

Matriz de varianzas y covarianzas de $\hat{\beta}$

- ¿Qué dimensión tiene $\text{VarCov}(\hat{\beta}) = \sigma^2(X'X)^{-1}$?

$$\text{VarCov}[\hat{\beta}] = \begin{bmatrix} V[\hat{\beta}_1] & \text{Cov}[\hat{\beta}_1, \hat{\beta}_2] & \cdots & \text{Cov}[\hat{\beta}_1, \hat{\beta}_K] \\ \text{Cov}[\hat{\beta}_1, \hat{\beta}_2] & V[\hat{\beta}_2] & \cdots & \text{Cov}[\hat{\beta}_2, \hat{\beta}_K] \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}[\hat{\beta}_1, \hat{\beta}_K] & \text{Cov}[\hat{\beta}_2, \hat{\beta}_K] & \cdots & V[\hat{\beta}_K] \end{bmatrix}$$

- Notar:
 - cada elemento de la diagonal es $V[\hat{\beta}_k] = \sigma^2 A_{kk}$, $k = 1, \dots, K$, donde A_{kk} es el elemento en la fila k y columna k de la matriz $(X'X)^{-1}$
 - cada elemento fuera de la diagonal es $\text{Cov}[\hat{\beta}_j, \hat{\beta}_k] = \sigma^2 A_{jk}$, $j \neq k$, donde A_{jk} es el elemento en la fila j y columna k de la matriz $(X'X)^{-1}$

$VarCov(\hat{\beta})$ en la práctica

- $VarCov(\hat{\beta})$ depende de σ^2 , un valor desconocido.
- En su lugar usaremos un estimador insesgado:

$$S^2 = \frac{1}{n-K} \sum_{i=1}^n e_i^2 = \frac{e'e}{n-K}$$

- Luego, el estimador de la matriz de varianzas y covarianzas es:

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

Bibliografía para esta clase

- Notas de clase, capítulo 2 secciones 2.1 a 2.9.
- Wooldridge, capítulo 6.3 (R cuadrado y R cuadrado ajustado)