
MODELOS CON MUCHAS VARIABLES EXÓGENAS

ECONOMETRÍA I

Miguel A. Delgado

■ **Objetivos básicos:**

- ▶ Modelo de correlación y de regresión: Interpretación y propiedades.
- ▶ Interpretación de los coeficientes: análisis ceteris paribus.
- ▶ Función de regresión corta y larga: relación entre los coeficientes.

1

Econometría I

MODELO Y PARÁMETROS

■ *Variable de interés:* Es una variable $k + 1$ -dimensional:

$$\underline{Z} = \begin{pmatrix} Y \\ X_1 \\ \vdots \\ X_k \end{pmatrix}.$$

Estamos interesados en explicar y cuantificar la relación causal entre (X_1, \dots, X_k) e Y .

Y → variable endógena o explicada

X_1, \dots, X_k → variables explicativas o exógenas.

2

El modelo económico nos proporciona una relación entre estas variables:

$$Y = f(X_1, X_2, \dots, X_k).$$

Esta relación puede ser lineal, en cuyo caso:

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k$$

INTERPRETACIÓN: Si mantenemos constante X_j , $j \neq i$

$$\Delta Y = \beta_j \Delta X_j \implies \beta_j = \frac{\Delta Y}{\Delta X_j}$$

$\implies \beta_i$ es la variación de Y cuando varía X_i en una unidad, mateniendo el resto de variables inalteradas (*ceteris paribus*).

MODELO DE CORRELACIÓN

■ *Predictor lineal óptimo de Y dado X_1, \dots, X_k ::*

$$PLO(Y | X_1, \dots, X_k) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k,$$

donde:

$$\begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} = \underset{\bar{\beta}_0, \bar{\beta}_1, \dots, \bar{\beta}_k}{\text{arg min}} E \left[\left(Y - \bar{\beta}_0 - \bar{\beta}_1 X_1 - \dots - \bar{\beta}_k X_k \right)^2 \right].$$

INTERPRETACIÓN: Si escribimos cualquier modelo lineal en términos de un error ε ,

$$Y = \bar{\beta}_0 + \bar{\beta}_1 X_1 + \dots + \bar{\beta}_k X_k + \varepsilon, \text{ con } E(\varepsilon) = 0,$$

El *PLO* es la combinación lineal de X_1, \dots, X_k que minimiza la varianza del error. Es la mejor manera de predecir los sucesos de Y a partir de una combinación lineal de las variables exógenas.

Los coeficientes tienen una fórmula explícita que derivamos en el caso $k = 2$.

$$\begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{pmatrix} = \underset{\bar{\beta}_0, \bar{\beta}_1, \dots, \bar{\beta}_k}{\text{arg min}} E \left[(Y - \bar{\beta}_0 - \bar{\beta}_1 X_1 - \bar{\beta}_2 X_2)^2 \right].$$

\implies Condiciones de primer orden:

$$\left. \begin{aligned} E[Y - \beta_0 - \beta_1 X_1 - \beta_2 X_2] &= 0 \\ E[X_1(Y - \beta_0 - \beta_1 X_1 - \beta_2 X_2)] &= 0 \\ E[X_2(Y - \beta_0 - \beta_1 X_1 - \beta_2 X_2)] &= 0 \end{aligned} \right\}$$

$$\beta_0 = E(Y) - \beta_1 E(X_1) - \beta_2 E(X_2)$$

$$\implies \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} = \begin{bmatrix} V(X_1) & C(X_1, X_2) \\ C(X_1, X_2) & V(X_2) \end{bmatrix}^{-1} \begin{pmatrix} C(Y, X_1) \\ C(Y, X_2) \end{pmatrix}$$

⇒ Hecho importante: Si $C(X_1, X_2) = 0$,

$$\beta_1 = \frac{C(Y, X_1)}{V(X_1)} \text{ la pendiente del } PLO(Y|X_1)$$

$$\beta_2 = \frac{C(Y, X_2)}{V(X_2)} \text{ la pendiente del } PLO(Y|X_2),$$

pero en general, cuando $C(X_1, X_2) \neq 0$,

$$\beta_1 = \frac{V(X_2)C(Y, X_1) - C(X_1, X_2)C(Y, X_2)}{V(X_1)V(X_2) - C(X_1, X_2)^2}$$

y

$$\beta_2 = \frac{V(X_1)C(Y, X_2) - C(X_1, X_2)C(Y, X_1)}{V(X_1)V(X_2) - C(X_1, X_2)^2}$$

7

También podemos expresar:

$$\underbrace{\frac{C(Y, X_1)}{V(X_1)}}_{\delta_{11}} = \beta_1 + \beta_2 \underbrace{\frac{C(X_1, X_2)}{V(X_1)}}_{\gamma_{11}} \quad \text{y} \quad \underbrace{\frac{C(Y, X_2)}{V(X_2)}}_{\delta_{12}} = \beta_2 + \beta_1 \underbrace{\frac{C(X_1, X_2)}{V(X_2)}}_{\gamma_{12}}.$$

Si definimos:

$$PLO(Y|X_j = x_j) = \delta_{0j} + \delta_{1j}x_j \begin{cases} \delta_{0j} = E(Y) - \delta_{1j}E(X_j) \\ \delta_{1j} = C(Y, X_j)/V(X_j) \end{cases}, \quad j = 1, 2$$

$$PLO(X_i|X_j = x_j) = \gamma_{0j} + \gamma_{1j}x_j \begin{cases} \gamma_{0j} = E(X_i) - \gamma_{1j}E(X_j) \\ \gamma_{1j} = C(X_i, X_j)/V(X_j) \end{cases}, \quad i \neq j = 1, 2$$

8

■ En el caso general:

$$\beta_0 = E(Y) - \beta_1 E(X_1) - \beta_2 E(X_2) - \dots - \beta_k E(X_k)$$

$$\begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{pmatrix} = \begin{bmatrix} V(X_1) & C(X_1, X_2) & \cdots & C(X_1, X_k) \\ C(X_2, X_1) & V(X_2) & \cdots & C(X_2, X_k) \\ \vdots & \vdots & \ddots & \vdots \\ C(X_k, X_1) & C(X_k, X_2) & \cdots & V(X_k) \end{bmatrix}^{-1} \begin{pmatrix} C(Y, X_1) \\ C(Y, X_2) \\ \vdots \\ C(Y, X_k) \end{pmatrix}$$

■ Coeficiente de correlación R^2 :

$$R^2 = \frac{V(PLO(Y | X_1, \dots, X_k))}{V(Y)} = 1 - \frac{V(\varepsilon)}{V(Y)},$$

⇒ El R^2 es la proporción de la varianza de Y explicada por el $PLO(Y | X_1, \dots, X_k)$

MODELO DE REGRESIÓN LINEAL

■ El modelo de regresión múltiple consiste en la esperanza condicional con varias variables exógenas:

$$g(x_1, \dots, x_k) = E(Y | X_1 = x_1, X_2 = x_2, \dots, X_k = x_k)$$

Cuando el modelo de regresión de Y dado X_1, \dots, X_k es una combinación lineal de X_1, \dots, X_k , diremos que el modelo de regresión es lineal. Entonces:

$$\begin{aligned} E(Y | X_1, X_2, \dots, X_k) &= \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \\ &= PLO(Y | X_1, X_2, \dots, X_k) \end{aligned}$$

► *Interpretación de los coeficientes:* Si todas las variables, excepto la X_j permanecen constantes:

$$\Delta E(Y | X_1 = x_1, X_2 = x_2, \dots, X_k = x_k) = \beta_j \Delta X_j$$
$$\implies \beta_j = \frac{\Delta E(Y | X_1 = x_1, X_2 = x_2, \dots, X_k = x_k)}{\Delta X_j}$$

β_j es la variación media de Y cuando X_j varía en una unidad ceteris paribus (todas las demás variables permaneciendo constantes).

■ *Ejemplo:* Supongamos que estamos interesados en estudiar la relación en una población entre Y =salario y X_1 =años de educación, teniendo en cuenta

$$X_2 = \text{género} = \begin{cases} 1 & \text{si mujer} \\ 0 & \text{si hombre} \end{cases} .$$

La a función $E(Y | X_1, X_2)$ toma los siguientes valores:

		$E(Y X_1, X_2)$		
$X_2 \setminus X_1$		8	12	16
0		30	38	46
1		26	34	42

$$\implies E(Y | X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 = 14 + 2X_1 - 4X_2.$$

■ *Función de regresión corta y larga*: Supongamos que:

$$E(Y|X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 \rightarrow \text{regresión larga.}$$

La esperanza condicional corta con respecto a X_1 será:

$$\frac{E(Y|X_1)}{E[E(Y|X_1, X_2)|X_1]} = \beta_0 + \beta_1 X_1 + \beta_2 E(X_2|X_1) \rightarrow \text{regresión corta.}$$

Por tanto:

$$E(Y|X_1) \neq PLO(Y|X_1) \text{ si } E(X_2|X_1) \text{ no es lineal.}$$

$$\blacktriangleright E[Y|X_1 = x_1, X_2 = x_2] - E[Y|X_1 = x_1 + 1, X_2 = x_2] = \beta_1, \text{ todo } x_1, x_2,$$

$$\blacktriangleright E[Y|X_1 = x_1] - E[Y|X_1 = x_1 + 1]$$

$$= \beta_1 + \beta_2 \{E[X_2|X_1 = x_1] - E[X_2|X_1 = x_1 + 1]\}, \text{ todo } x_1, x_2,$$

$$\implies \Delta E[Y|X_1 = x_1] = \beta_1 + \beta_2 \Delta E[X_2|X_1 = x_1].$$

Si:

$$E(X_2|X_1) = \gamma_{01} + \gamma_{11}X_1 = PLO(X_2|X_1) \implies \begin{cases} \gamma_{01} = E(X_2) - \delta_{11}E(X_1) \\ \gamma_{11} = C(X_1, X_2)/V(X_1) \end{cases},$$

entonces:

$$E(Y|X_1) = \underbrace{(\beta_0 + \gamma_{01})}_{\delta_{01}} + \underbrace{(\beta_1 + \beta_2\gamma_{11})}_{\delta_{11}}X_1$$

$$\implies \delta_{11} = \frac{C(Y, X_1)}{V(X_1)} = \beta_1 + \beta_2 \frac{C(X_1, X_2)}{V(X_1)} = \beta_1 + \beta_2\gamma_{11}.$$

■ *Ejemplo:* Supongamos en el último ejemplo que la función de probabilidad conjunta de X_1, X_2 , y sus correspondientes marginales son las siguientes:

$$\Pr(X_1 = x_1, X_2 = x_2)$$

$X_2 \setminus X_1$	8	12	16	
0	0,05	0,30	0,15	0,50
1	0,15	0,30	0,05	0,50
	0,20	0,60	0,20	

Por la Ley de la Esperanza Iterada:

$$E(Y|X_1 = x) = E[E(Y|X_1, X_2)|X_1 = x].$$

Por tanto:

$$\begin{aligned} E(Y|X_1 = 8) &= E[E(Y|X_1, X_2)|X_1 = 8] \\ &= E(Y|X_1 = 8, X_2 = 0) \Pr(X_2 = 0|X_1 = 8) \\ &\quad + E(Y|X_1 = 8, X_2 = 1) \Pr(X_2 = 1|X_1 = 8) \end{aligned}$$

$$E(Y|X_1 = 8) = 30 \times \frac{0,05}{0,20} + 26 \times \frac{0,15}{0,20} = 27$$

$$E(Y|X_1 = 12) = 38 \times \frac{0,30}{0,60} + 34 \times \frac{0,30}{0,60} = 36$$

$$E(Y|X_1 = 16) = 46 \times \frac{0,15}{0,20} + 42 \times \frac{0,05}{0,20} = 45$$

17

$$E(Y|X_2 = 0) = E[E(Y|X_1, X_2)|X_2 = 0] = 39,6$$

$$E(Y|X_2 = 1) = E[E(Y|X_1, X_2)|X_2 = 1] = 32,4$$

$$\implies E(Y|X_1) = 9 + 2,25 \cdot X_1 \quad \text{y} \quad E(Y|X_2) = 39,6 - 7,20 \cdot X_2.$$