

# ECONOMETRÍA I

## Tema 3: El Modelo de Regresión Lineal Múltiple: estimación

Patricia Moreno  
Juan Manuel Rodríguez Poo  
Alexandra Soberon  
Departamento de Economía

Existen diversos problemas que no pueden ser resueltos con el modelo de regresión simple:

- Es complicado extraer conclusiones *ceteris paribus*. A la hora de realizar un análisis causal es mejor controlar más factores que recurrir al supuesto de media condicional cero,  $E(u|x) = 0$ .
- Si usamos un único regresor, solamente somos capaces de explicar una parte limitada de la variabilidad de  $y$  en función de la información proporcionada por esa  $x$ .
- Sólo se puede incorporar una relación funcional concreta entre  $x$  e  $y$  (en función de  $x$ ,  $\log x$ , etc.)

- **Objetivo:** determinar el impacto de la educación (*educ*) sobre los salarios (*wage*) cuando también se conoce la experiencia laboral (*exper*).

$$wage = \beta_0 + \beta_1 educ + \beta_2 exper + u.$$

- Este modelo incluye *exper* para controlar su efecto sobre *wage*.
- Incorporar *exper* explícitamente es importante porque la educación y la experiencia laboral están positivamente correlacionados.
- En el modelo de regresión lineal la experiencia está incluida en el término de error por lo que el estimador MCO estaría sesgado.

# Modelo de regresión lineal múltiple

- El Modelo de Regresión Lineal Múltiple nos permite explicar relaciones económicas en las que intervienen más de dos variables.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k + u,$$

donde

- $\beta_0$ : término de intercepto.
  - $\beta_j$  ( $j = 1, \dots, k$ ): parámetro de la pendiente. Se interpreta como el efecto parcial sobre  $y$  de un cambio en  $x_j$ , *ceteris paribus*.
  - $u$ : término de error.
- **Supuesto clave:**  $E(u|x_1, \dots, x_k) = 0$ .

**Objetivo:** explicar el efecto del gasto por estudiante (*expend*) sobre la calificación media en un examen estandarizado (*avgscore*) controlando también por el ingreso familiar medio (*avginc*).

$$avgscore = \beta_0 + \beta_1 expend + \beta_2 avginc + u,$$

donde

- $\beta_0$ : intercepto.
- $\beta_1$ : mide cómo cambia *avgscore* ante un cambio en *expend*, manteniendo todos los demás factores constantes.
- $\beta_2$ : mide cómo cambia *avgscore* ante un cambio en *avginc*, manteniendo todos los demás factores constantes.

# Modelo de regresión múltiple

- **Objetivo:** estimar un modelo en el cual  $x_1$  y  $x_2$  están correlacionados perfectamente pero no de forma lineal.

$$cons = \beta_0 + \beta_1 inc + \beta_2 inc^2 + u,$$

donde *cons* es el consumo del hogar e *inc* es el ingreso del hogar.

- Como en este caso estimamos un modelo de regresión múltiple pero la renta es el único factor que afecta al consumo, la interpretación de los parámetros cambia dado que  $x_2$  no puede ser constante si  $x_1$  cambia.
- $\beta_1$  y  $\beta_2$  no tienen interpretación por separado.
- Propensión marginal a consumir:

$$\frac{\Delta cons}{\Delta inc} = \beta_1 + 2\beta_2 inc.$$

# Modelo de regresión con 2 variables: MCO

- Los estimadores MCO resuelven el siguiente problema

$$\min_{\beta_0, \beta_1, \beta_2} \sum_{i=1}^n \left( y_i - \hat{\beta}_0 - x_{1i}\hat{\beta}_1 - x_{2i}\hat{\beta}_2 \right)^2.$$

de modo que los estimadores MCO minimizan el promedio de la diferencia al cuadrado entre los valores actuales  $y_i$  y los valores predichos (línea estimada).

- **Condiciones de primer orden:**

$$\sum_{i=1}^n \left( y_i - \hat{\beta}_0 - x_{1i}\hat{\beta}_1 - x_{2i}\hat{\beta}_2 \right) = 0,$$

$$\sum_{i=1}^n x_{1i} \left( y_i - \hat{\beta}_0 - x_{1i}\hat{\beta}_1 - x_{2i}\hat{\beta}_2 \right) = 0,$$

$$\sum_{i=1}^n x_{2i} \left( y_i - \hat{\beta}_0 - x_{1i}\hat{\beta}_1 - x_{2i}\hat{\beta}_2 \right) = 0.$$

- Sea la ecuación estimada

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2$$

- Los estimadores de las pendientes se interpretan como efectos parciales o *ceteris paribus*, i.e.,

$$\Delta \hat{y} = \hat{\beta}_0 + \hat{\beta}_1 \Delta x_1 + \hat{\beta}_2 \delta x_2,$$

donde

- $\hat{\beta}_1 = \frac{\Delta E[y|x_1, x_2]}{\Delta x_1}$ : Si  $x_1$  varía 1 unidad,  $y$  varía en promedio  $\beta_1$  unidades de  $y$  cuando  $x_2$  se mantiene constante, i.e., cuando  $\Delta x_2 = 0$ ,  $\Delta \hat{y} = \hat{\beta}_1 \Delta x_1$ .
- $\hat{\beta}_2 = \frac{\Delta E[y|x_1, x_2]}{\Delta x_2}$ : si  $x_2$  varía 1 unidad,  $y$  varía en promedio  $\beta_2$  unidades de  $y$  *ceteris paribus*, i.e., cuando  $\Delta x_1 = 0$ ,  $\Delta \hat{y} = \hat{\beta}_2 \Delta x_2$ .
- $\beta_0$ : valor predicho del promedio de  $y$  cuando  $x_1 = x_2 = 0$ .



- **Modelo:** Cuando queremos modelizar la relación entre  $x$  e  $y$  considerando la existencia de efectos marginales crecientes o decrecientes el modelo a considerar es:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + u,$$

donde  $E(u|x) = 0 \implies E(y|x) = \beta_0 + \beta_1 x + \beta_2 x^2$ .

- **Interpretación:** cuando  $x$  varía 1 unidad,  $y$  varía en media en  $(\beta_1 + 2\beta_2 x)$  unidades de  $y$ , i.e.

$$\frac{\Delta E(y|x)}{\Delta x} = \beta_1 + 2\beta_2 x.$$

- $\beta_1$  y  $\beta_2$  no tienen interpretación por separado.
- Existe un valor crítico ( $x^* = -\beta_1/2\beta_2$ ) en el que el efecto de  $x$  sobre  $E(y|x)$  cambia de signo.

- Sea el modelo de regresión con  $k$  variables explicativas,

$$Y = X\beta + u.$$

- $Y$  es un vector  $n \times 1$  de observaciones de  $Y$ .
- $X$  es una matriz  $n \times k$  de observaciones de las variables explicativas.
- $u$  es un vector  $n \times 1$  de perturbaciones no observables.

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix}, \quad X = \begin{pmatrix} 1 & X_{11} & \cdots & X_{k1} \\ 1 & X_{12} & \cdots & X_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & X_{1n} & \cdots & X_{kn} \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}, \quad u = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

- **Modelo de regresión ajustado:**  $Y = X\hat{\beta} + \hat{u}$ ,
- **Residuos al cuadrado:**

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

- **Condición de primer orden:**

$$\frac{\partial(\hat{u}'\hat{u})}{\partial\hat{\beta}} = -2X'(Y - X\hat{\beta}) = 0_k,$$

Esta c.p.o. es la misma que  $X'\hat{u} = 0$ . Reordenando  $X'X\hat{\beta} = X'Y$ .

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

- **Valores ajustados:**  $\hat{Y} = X\hat{\beta}$ .
- **Residuos:**  $\hat{u} = Y - \hat{Y} = Y - X\hat{\beta}$ .
- **Propiedades:**
  - La suma de los residuos MCO es cero:  $\sum_{i=1}^n \hat{u}_i = 0$ .
  - La media muestral de los residuos es cero. Así  $\bar{Y} = \overline{\hat{Y}}$ .
  - La covarianza muestral entre cada una de las variables independientes y los residuos MCO es cero.
  - La línea de regresión MCO siempre va a través de la media de la muestra ( $\bar{Y} = X\hat{\beta}$ ). Así,

$$X'[Y - X\hat{\beta}] = X'\hat{u} = 0_k.$$

- Dado que la variación total en  $y_i$  es igual a la suma de la variación total en  $\hat{y}_i$  y en  $\hat{u}_i$  ( $y_i = \hat{y}_i + \hat{u}_i$ ) podemos definir:
  - **Suma Total de los Cuadrados (STC):**

$$STC = \sum_{i=1}^n (y_i - \bar{y})^2 \rightarrow STC = Y'Y - n\bar{Y}^2 = Y'M_iY.$$

- **Suma de Cuadrados Explicada (SCE):**

$$SCE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \rightarrow SCE = \hat{Y}'\hat{Y} - n\bar{Y}^2 = \hat{Y}'M_i\hat{Y}.$$

- **Suma de Cuadrados de los Residuos (SCR):**

$$SCR = \sum_{i=1}^n \hat{u}_i^2 \rightarrow SCR = \hat{u}'\hat{u} = Y'MY.$$

donde  $M_i = I_n - v(v'v)^{-1}v'$  y  $M = I - X(X'X)^{-1}X'$ .

- $SST = SSE + SSR$ .
- Suponiendo que la variación total en  $Y$  no sea cero,

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST} = 1 - \frac{Y'MY}{Y'M_iY},$$

- $R^2$  representa la proporción de la variación muestral en  $Y$  que es explicada por la línea de regresión MCO.

- $R^2$  también puede ser entendido como el coeficiente de correlación al cuadrado entre el valor actual  $y_i$  y el valor predicho  $\hat{y}_i$ :

$$R^2 = \frac{\left(\sum_{i=1}^n (y_i - \bar{y})(\hat{Y}_i - \bar{\hat{y}})\right)^2}{\left(\sum_{i=1}^n (y_i - \bar{y})^2\right) \left(\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2\right)}.$$

- **Propiedades  $R^2$ :**

- $0 \leq R^2 \leq 1$ .
- $R^2$  nunca disminuye cuando otra variable independiente es añadida a la regresión. Normalmente aumenta.
- $R^2$  no es un instrumento muy confiable para decidir si incluir o no un nuevo regresor en la regresión dado que normalmente siempre aumenta a medida que se incorporan más variables explicativas.

- En ocasiones la teoría económica impone la restricción de que cuando  $X_k = 0$  el valor esperado de  $Y$  es cero, es decir,  $\beta_0 = 0$ . Por ejemplo, si los ingresos son iguales a cero ( $X = 0$ ) los impuestos asociados al trabajo también son iguales a cero ( $Y = 0$ ).
- **Modelo:**  $y_i = \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki}$ ,  $i = 1, \dots, n$ .
- El estimador MCO minimiza el problema

$$\sum_{i=1}^n (y_i - \tilde{\beta}_j x_{ji})^2, \quad j = 1, \dots, k.$$

- **Condiciones de primer orden:**

$$\sum_{i=1}^n x_{ji} (y_i - \tilde{\beta}_j x_{ji}) = 0$$



- **Estimador MCO:**

$$\tilde{\beta}_j = \frac{\sum_{i=1}^n x_{ji} y_i}{\sum_{i=1}^n x_{ji}^2}$$

- El ajuste MCO ya no satisface las mismas condiciones que en el caso general:
  - $\hat{u}$  ya no tienen media muestral cero.
  - Si definimos  $R^2 = 1 - SSR/SST$  entonces  $R^2$  puede ser negativa.
  - Si  $\beta_0 \neq 0$ , los estimadores MCO pueden estar sesgados.

# Regresión simple vs regresión múltiple

- **Regresión simple:**  $\tilde{y}_i = \tilde{\beta}_0 + \tilde{\beta}_1 x_{1i}$ .
- **Regresión múltiple:**  $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i}$ .
- Parcializando obtenemos la siguiente relación

$$\tilde{\beta}_1 = \hat{\beta}_1 \frac{\sum_{i=1}^n \hat{r}_{1i} x_{1i}}{\sum_{i=1}^n \hat{r}_{1i}^2} + \hat{\beta}_k \frac{\sum_{i=1}^n \hat{r}_{1i} x_{ki}}{\sum_{i=1}^n \hat{r}_{1i}^2} + \hat{\beta}_k \frac{\sum_{i=1}^n \hat{r}_{1i} \hat{r}_{2i}}{\sum_{i=1}^n \hat{r}_{1i}^2}$$

$$\tilde{\beta}_1 = \hat{\beta}_1 + \hat{\beta}_k \tilde{\delta}_1.$$

- Normalmente,  $\tilde{\beta}_1 \neq \hat{\beta}_1$  aunque existen dos casos en que  $\tilde{\beta}_1 = \hat{\beta}_1$ .
  - $\hat{\beta}_2 = 0$ : el efecto parcial de  $X_2$  sobre  $\hat{Y}$  es cero.
  - $\tilde{\delta}_1$ :  $X_1$  y  $X_2$  no están correlacionadas en la muestra.

- **Objetivo:** comparación entre estimación de regresión simple y de regresión múltiple.
- El modelo lineal general  $Y = X\hat{\beta} + \hat{u}$  se puede escribir como

$$Y = X_r \hat{\beta}_r + X_s \hat{\beta}_s + \hat{u}$$

donde  $X_r$  y  $X_s$  son submatrices de dimensión  $n \times r$  y  $n \times s$ , respectivamente.  $\hat{\beta}_r$  es un subvector  $r \times 1$  que contiene los  $r$  primeros parámetros de  $\hat{\beta}$  y  $\hat{\beta}_s$  es un subvector  $s \times 1$  que contiene los  $s = k - r$  restantes de  $\hat{\beta}$ .

- Sean  $H$  y  $M$  matrices de proyección (simétrica e idempotente)

$$H = X(X'X)^{-1}X' \quad \text{y} \quad M = I - X(X'X)^{-1}X'.$$

- Sea la matriz

$$M_s = I_n - X_s(X_s'X_s)^{-1}X_s',$$

multiplicamos el modelo por  $M_s$

$$M_s Y = M_s X_r \hat{\beta}_r + M_s X_s \hat{\beta}_s + M_s \hat{u}$$

y dado que  $M_s X_s = 0$  y  $M \hat{u} = MMY = MY = \hat{u}$ ,

$$M_s Y = M_s X_r \hat{\beta}_r + M_s \hat{u}.$$

- **Estimador MCO:**

$$\hat{\beta}_r = (X_r' M_s' M_s X_r)^{-1} X_r' M_s' M_s Y = (X_r' M_s X_r)^{-1} X_r' M_s Y.$$

- Considerando el caso en que  $k = 2$ ,  $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2$ ,

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n \hat{r}_{i1} y_i}{\sum_{i=1}^n \hat{r}_{i1}^2},$$

donde  $\hat{r}_{i1}$  son los residuos de la regresión estimada  $\hat{X}_1 = \hat{\gamma}_0 + \hat{\gamma}_2 X_2$ .

- Interpretación: sólo la parte de  $x_{1i}$  que está incorrelacionada con  $x_{2i}$  está relacionada con  $y_i$ . Por lo tanto, estamos estimando el efecto de  $x_1$  sobre  $y$  después de que  $x_2$  haya sido parcializado.

- Supuestos:

- **RLM.1:** *Linealidad en parámetros:*

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u.$$

- **RLM.2:** *Muestreo aleatorio.* Usamos un muestreo aleatorio con  $n$  observaciones  $\{(x_{1i}, x_{2i}, \cdots, x_{ki}) : i = 1, 2, \cdots, n\}$  de acuerdo con el modelo poblacional propuesto. Así,

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \cdots + \beta_k x_{ki} + u_i.$$

- **RLM.3:** *No hay multicolinealidad perfecta.* Ninguno de los regresores es constantes y tampoco existen relaciones lineales exactas entre las variables independientes.
- **RLM.4:** *Media condicional cero:*  $E(u|x_1, x_2, \cdots, x_k) = 0$ . Así, todas las variables explicativas son exógenas.

**Teorema** Bajo los supuestos RML.1-RML.4, el estimador MCO  $\hat{\beta}_j$  es insesgado para  $\beta_j$

$$E(\hat{\beta}_j) = \beta_j, \quad j = 1, \dots, k,$$

para cualquier valor de los parámetros poblacionales  $\beta_j$ .

- El supuesto clave es RML.3.
- La propiedad de insesgadez no dice nada sobre el resultado de la estimación. Sólo es una propiedad del método de estimación MCO.

- **Supuestos:**

- **(A.1)** El modelo puede ser escrito como  $Y = X\beta + u$ , donde  $Y$  es un vector  $n \times 1$  observado,  $X$  es una matriz observada  $n \times k$  y  $u$  es un vector  $n \times 1$  de términos de error no observados.
- **(A.2)** La matriz  $X$  tiene rango  $k$ .
- **(A.3)** Cada error  $v_i$  tiene media cero, condicional a toda la matrix  $X$ ,  $E(u_i|X) = 0$ .

- **Teorema:** Bajo los supuestos **(A.1)**-**(A.3)**, el estimador MCO  $\hat{\beta}$  es insesgado para  $\beta$ .

$$E(\hat{\beta}) = \beta$$

*Proof.*

$$E(\hat{\beta}) = \beta + E_X\{(X'X)^{-1}X'E(u|X)\}.$$



- **Sobre-especificación** del modelo de regresión múltiple: cuando una o más regresores están incluidos en el modelo a pesar de que en la población no tienen efecto parcial en  $y$ .
- Sea

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3,$$

donde  $X_3$  no tiene efecto sobre  $Y$  una vez controladas por  $X_1$  y  $X_2$  por lo que  $\beta_3 = 0$ ,

$$E(Y|X_1, X_2, X_3) = E(Y|X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2.$$

- Efectos de la inclusión de variables irrelevantes: Ninguno.  
 $E(\hat{\beta}_3) = \beta_3 = 0$  y el estimador MCO sigue siendo insesgado.

- Cuando omitimos una variable relevante (subespecificamos el modelo) incurrimos en un caso particular de **error de especificación**.
- **Efecto de la subespecificación**: los estimadores MCO normalmente serán sesgados. ¿Por qué?
- **Modelo verdadero**:

$$wage_i = \beta_0 + \beta_1 educ_i + \beta_2 abil_i + u_i.$$

- **Modelo a estimar**:

$$wage_i = \beta_0 + \beta_1 educ_i + v_i, \quad v_i = \beta_2 abil_i + u_i.$$

- **Estimador MCO**: siendo  $x_1 = educ$ ,

$$\tilde{\beta}_1 = \frac{\sum_{i=1}^n (x_{1i} - \bar{x}_1) y_i}{\sum_{i=1}^n (x_{1i} - \bar{x}_1)^2}.$$

- Reemplazando  $\tilde{\beta}_1$  en el verdadero modelo y siendo  $x_2 = \text{abil}$ ,

$$\sum_{i=1}^n (x_{1i} - \bar{x}_1)(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + u_i)$$

y usando  $E(u_i) = 0$ ,

$$E(\tilde{\beta}_1) = \beta_1 + \beta_2 \frac{\sum_{i=1}^n (x_{1i} - \bar{x}_1)x_{2i}}{\sum_{i=1}^n (x_{1i} - \bar{x}_1)^2}$$

ó

$$E(\tilde{\beta}_1) = \beta_1 + \beta_2 \tilde{\delta}_1,$$

donde  $\tilde{\delta}_1$  es el coeficiente de la pendiente de regresión ( $\tilde{x}_2 = \tilde{\delta}_0 + \tilde{\delta}_1 x_1$ ) usando la misma muestra.

- Así,  $\tilde{\beta}_1$  está sesgado para estimar  $\beta_1$ :

$$\text{Sesgo}(\tilde{\beta}_1) = E(\tilde{\beta}_1) - \beta_1 = \beta_2 \tilde{\delta}_1.$$

- Existen dos situaciones en las cuales  $\tilde{\beta}_1$  es insesgado:
  - Si  $\beta_2 = 0$ , por lo que  $x_2$  no aparece en el modelo poblacional.
  - Si  $\tilde{\delta}_1 = 0$ , es decir, la covarianza muestral entre  $x_1$  y  $x_2$  es cero.
- **Signo del sesgo:**  $Sesgo(\tilde{\beta}_1) = E(\tilde{\beta}_1) - \beta_1 = \beta_2 \tilde{\delta}_2$ .

	$Corr(x_1, x_2) > 0$	$Corr(x_1, x_2) < 0$
$\beta_2 > 0$	Sesgo positivo	Sesgo negativo
$\beta_2 < 0$	Sesgo negativo	Sesgo positivo

- **Objetivo:** determinar el impacto de la omisión de múltiples regresores en el modelo estimado.
- **Modelo poblacional:**

$$Y = X_r \beta_r + X_s \beta_s + u.$$

- **Modelo a estimar:**

$$Y = X_r \beta_r + \epsilon, \quad \epsilon = X_s \beta_s + u.$$

$$\begin{aligned} \hat{\beta}_r &= (X_r' X_r)^{-1} X_r' Y \Rightarrow \hat{\beta}_r = (X_r' X_r)^{-1} X_r' [X_r \beta_r + X_s \beta_s + u] \\ &= \beta_r + (X_r' X_r)^{-1} X_r' X_s \beta_s + (X_r' X_r)^{-1} X_r' u. \end{aligned}$$

- **Sesgo por error de especificación:**

$$E(\hat{\beta}_r) = \beta_r + \underbrace{(X_r' X_r)^{-1} X_r' X_s \beta_s}_{\text{Sesgo}}$$

# Varianza de los estimadores MCO

- Además de saber que la distribución muestral de  $\hat{\beta}_j$  está centrada, es importante conocer su variabilidad alrededor de  $\beta_j$ .
- Para hallar la varianza debemos añadir el supuesto de homocedasticidad.
- **RLM.5: Homocedasticidad condicional.** Dado cualquier valor  $x$  para  $(x_1, x_2, \dots, x_k)$ , el término de error  $u$  tiene la misma varianza, es decir,

$$\text{Var}(u|x_1, x_2, \dots, x_k) = \sigma^2.$$

Si esto no se cumple, estaríamos en presencia de heterocedasticidad.

- Los cuatro supuestos sobre la insesgadez (**RLM.1-RLM.4**) junto con este supuesto de homocedasticidad son conocidos como los **supuestos de Gauss-Markov**.

# Varianza de los estimadores MCO

Bajo los supuestos **RLM.1-5**, condicional en los valores de las variables independientes,

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}, \quad j = 1, \dots, k,$$

donde

- $R_j^2$  es el  $R^2$  de la regresión de  $x_j$  sobre todos los demás regresores (y el término constante).
- $SST_j$  es la variación total de  $x_j$ , es decir,

$$SST_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2.$$

# Varianza MCO: notación matricial

$$\begin{aligned}
 E[uu'|X] &= E \left[ \begin{array}{c} \left( \begin{array}{c} u_1 \\ u_2 \\ \vdots \\ u_n \end{array} \right) \left( \begin{array}{cccc} u_1 & u_2 & \cdots & u_n \end{array} \right) \\ \left| \right. \\ X \end{array} \right] \\
 &= \begin{pmatrix} E(u_1^2|X) & E(u_1 u_2|X) & \cdots & E(u_1 u_n|X) \\ E(u_1 u_2|X) & E(u_2^2|X) & \cdots & E(u_2 u_n|X) \\ \vdots & \vdots & \cdots & \vdots \\ E(u_n u_1|X) & E(u_n u_2|X) & \cdots & E(u_n^2|X) \end{pmatrix}.
 \end{aligned}$$



# Varianza MCO: notación matricial

Si asumimos que la varianza del término de error es homocedástica,

$$E(uu'|X) = \begin{pmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{pmatrix} = \sigma^2 \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix}.$$

De este modo,

$$E[uu'|X] = \sigma^2 I_n,$$

donde  $I_n$  es una matriz diagonal  $n \times n$ .

# Varianza MCO: notación matricial

$$\begin{aligned}
 \text{Var}(\hat{\beta}|X) &= E [(\hat{\beta} - \beta)(\hat{\beta} - \beta)'|X] \\
 &= E [(X'X)^{-1}X'uu'X(X'X)^{-1}|X] \\
 &= \left[ (X'X)^{-1}X' \underbrace{E(uu'|X)}_{\sigma^2} X(X'X)^{-1} \right]
 \end{aligned}$$

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

- **Varianza del error,  $\sigma^2$ :** cuando mayor sea  $\sigma^2$  mayor será  $Var(\hat{\beta}_j)$ .
  - Es una propiedad de la población, no depende de  $n$  y es desconocido.
  - Para reducirla es necesario introducir más variables explicativas.  
Problema: en ocasiones no siempre es deseable ni posible.
- **Varianza total de  $x_j$ ,  $SST_j$ :** cuanto mayor  $SST_j$ , menor será  $Var(\hat{\beta}_j)$ .
- **Relación lineal entre los regresores:** un mayor  $R_j^2$  está asociado a una mayor  $Var(\hat{\beta}_j)$ .
  - $R_j^2 \simeq 1$ :  $X_j$  se puede explicar en gran parte por los otros regresores.
  - A una correlación fuerte (pero no perfecta) entre 2 o más regresores se le conoce como **multicolinealidad**. Esta situación aumenta  $Var(\hat{\beta}_j)$ , como lo hace una muestra pequeña, todo lo demás igual.

# Varianza en los modelos mal especificados

- A la hora de decidir si incluir una variable o no en la regresión existe un trade-off entre el sesgo y la varianza.

- **Modelo verdadero:**

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + u$$

- **Estimador modelo regresión múltiple:**

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2.$$

- **Estimador modelo regresión simple:**

$$\tilde{Y} = \tilde{\beta}_0 + \tilde{\beta}_1 X_1.$$

- Si  $\beta_2 \neq 0$ ,  $\tilde{\beta}_1$  estará sesgado. Desde el punto de vista del sesgo  $\hat{\beta}_1$  será preferido.

# Varianza en los modelos mal especificados

- Desde el punto de vista de la varianza:

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{SST_1(1 - R_1^2)}$$

$$\text{Var}(\tilde{\beta}_1) = \frac{\sigma^2}{SST_1}.$$

Por lo tanto,

$$\text{Var}(\tilde{\beta}_1) < \text{Var}(\hat{\beta}_1).$$

- Si  $x_1$  y  $x_2$  están correlacionados:

$$\text{Var}(\tilde{\beta}_1) = \text{Var}(\hat{\beta}_1).$$

- Así, si  $x_1$  y  $x_2$  no están incorrelacionados:

- Si  $\beta_2 \neq 0$ ,  $\tilde{\beta}_1$  es sesgado,  $\hat{\beta}_1$  es insesgado y  $\text{Var}(\tilde{\beta}_1) < \text{Var}(\hat{\beta}_1)$ .
- Si  $\beta_2 = 0$ ,  $\tilde{\beta}_1$  y  $\hat{\beta}_1$  son insesgados y  $\text{Var}(\tilde{\beta}_1) < \text{Var}(\hat{\beta}_1)$ .

- **Modelo verdadero:**

$$Y = X_r \beta_r + X_s \beta_s + u$$

- **Modelo a estimar:**

$$Y = X_r \beta_r + \epsilon, \quad \epsilon = X_s \beta_s + u.$$

- **Estimador MCO:**

$$\tilde{\beta}_r = (X_r' X_r)^{-1} X_r' Y$$

- **Varianza del estimador mal especificado:**

$$V(\tilde{\beta}_r) = \sigma^2 (X_r' M_s X_r)^{-1}.$$

- **Varianza del estimador bien especificado:**

$$\begin{aligned}
 V(\hat{\beta}_r) &= E \left[ (\hat{\beta}_r - E(\hat{\beta}_r))(\hat{\beta}_r - E(\hat{\beta}_r))' \right] \\
 &= E \left[ (X_r' X_r)^{-1} X_r' u u' X_r (X_r' X_r)^{-1} \right] \\
 &= (X_r' X_r)^{-1} X_r' \underbrace{E(u u' | X_r)}_{\sigma^2 I_n} X_r (X_r' X_r)^{-1} = \sigma^2 (X_r' X_r)^{-1}
 \end{aligned}$$

- **Prueba de la varianza del modelo mal especificado:**

$$\begin{aligned}
 V(\tilde{\beta}_r) &= E \left[ (\tilde{\beta}_r - E(\tilde{\beta}_r))(\tilde{\beta}_r - E(\tilde{\beta}_r))' \right] \\
 &= E \left[ (X_r' M_S X_r)^{-1} X_r' M_S u u' M_S X_r (X_r' M_S X_r)^{-1} \right] \\
 &= (X_r' M_S X_r)^{-1} X_r' M_S \underbrace{E(u u' | X_r, X_S)}_{\sigma^2 I_n} M_S X_r (X_r' M_S X_r)^{-1} \\
 &= \sigma^2 (X_r' M_S X_r)^{-1} X_r' \underbrace{M_S M_S}_{M_S} X_r (X_r' M_S X_r)^{-1} = \sigma^2 (X_r' M_S X_r)^{-1}
 \end{aligned}$$

- Inversa de las dos varianzas:

$$\begin{aligned}V(\hat{\beta}_r)^{-1} - V(\tilde{\beta}_r)^{-1} &= \sigma^{-2} X_r' X_r - \sigma^{-2} X_r' M_s X_r \\ &= \sigma^{-2} X_r' [I_n - M_s] X_r \\ &= \sigma^{-2} X_r' [X_s (X_s' X_s)^{-1} X_s'] X_r.\end{aligned}$$

Esta matriz de diferencias será nula si  $X_s' X_r = 0$ .



# Estimación del error de varianza

- Hemos visto que  $\sigma^2 = E(u_i^2)$ , por lo que un estimador insesgado de  $\sigma^2$  es  $n^{-1} \sum_{i=1}^n u_i^2$ .
- Como los errores no son observables, no podemos estimar  $\sigma^2$ . Sin embargo, si podemos utilizar los residuos  $\hat{u}_i$  para obtener un estimador de  $\sigma^2$

$$\tilde{\sigma}^2 = \frac{SSR}{n} = \frac{1}{n} \sum_{i=1}^n \hat{u}_i^2.$$

- $\tilde{\sigma}^2$  es un estimador sesgado dado que  $\hat{u}_i$  satisfacen  $k + 1$  restricciones.
- El estimador insesgado de  $\sigma^2$  ajustado por los grados de libertad ( $n - k - 1$ ) es

$$\hat{\sigma}^2 = \frac{1}{n - k - 1} \sum_{i=1}^n \hat{u}_i^2 = \frac{SSR}{n - k - 1},$$

$$\hat{\sigma}^2 = \frac{\hat{u}'\hat{u}}{n-k} = \frac{\sum_{i=1}^n \hat{u}_i^2}{n-k},$$

dado que si  $M = (X'X)^{-1}X'$ ,

$$\hat{u} = MY = M[X\beta + u] = Mu$$

y

$$\hat{u}'\hat{u} = (Mu)'Mu = u'M'Mu = u'Mu.$$

# Valor esperado de la varianza estimada

Bajo los supuestos **RLM.1-5**,

$$E(\hat{\sigma}^2) = E\left(\frac{\hat{u}'\hat{u}}{n-k}\right) = \sigma^2$$

dado que

$$\begin{aligned} E(\hat{u}'\hat{u}) &= E(u'Mu) = E(\text{tr}(u'Mu)) = E(\text{tr}(Mu'u)) \\ &= \text{tr}E(Mu'u) = \text{tr}[ME(uu')] = \text{tr}\left[M(\sigma^2 I_n)\right] \\ &= \text{tr}\left[\sigma^2 M\right] = \sigma^2 \text{tr}M = \sigma^2(n-k). \end{aligned}$$

# Estimación del error de varianza

- Bajo **RLM.1-5**,  $E(\hat{\sigma}^2) = \sigma^2$ .
- **Error estándar de la regresión:**  $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$ .
- **Desviación estándar de  $\hat{\beta}_j$ :**

$$sd(\hat{\beta}_j) = \frac{\sigma}{[SST_j(1 - R_j^2)]^{1/2}}.$$

- **Error estándar de  $\hat{\beta}_j$ :**

$$se(\hat{\beta}_j) = \frac{\hat{\sigma}}{[SST_j(1 - R_j^2)]^{1/2}}.$$

Bajo los supuestos **RLM.1-5**,  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  son los estimadores lineales insesgados óptimos de  $\beta_0, \beta_1, \dots, \beta_k$ , respectivamente, son (**ELIOs**, también conocido como **BLUEs**), es decir, el

- **Estimador**
- **Lineal**
- **Insesgado**
- **Óptimo.**

Entonces, si los supuestos **RLM.1-5** se cumplen el estimador MCO es el mejor.