

# TEMA 3: PROPIEDADES DEL ESTIMADOR MCO



S. Álvarez, A. Beyaert, M. Camacho, M. González, A. Quesada  
Departamento de Métodos Cuantitativos para la Economía y la Empresa

UNIVERSIDAD DE  
MURCIA

# Lo que estudiaremos en este tema:

- 1. El valor esperado del estimador MCO**
  - 1.1 Supuestos necesarios para la insesgadez
  - 1.2 Errores de especificación e insesgadez del estimador MCO
  
- 2. La varianza del estimador MCO y su estimación**
  - 2.1 La varianza del estimador MCO
  - 2.2 Multicolinealidad fuerte y varianzas MCO
  - 2.3 El estimador de la varianza del estimador MCO
  - 2.4 Varianzas en modelos mal especificados
  
- 3. Optimalidad del estimador MCO**
  - 3.1 Supuestos necesarios
  - 3.2 El Teorema de Gauss-Markov
  
- 4. Consistencia del estimador MCO**
  - 4.1 Introducción
  - 4.2 Supuestos necesarios
  - 4.3 Teorema

*Bibliografía básica: Wooldridge, 2006, cap. 3 y 5*

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- Propiedad de insesgadez:

$$E(\hat{\beta}_j / x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}) = \beta_j, j = 0, 1, \dots, k$$

- $E(\hat{\beta}_j)$  es una medida de **posición** del estimador

- El estimador MCO de los coeficientes poblacionales  $\beta_0, \beta_1, \dots, \beta_k$  es **insesgado** si se cumplen **ciertos supuestos**:

- RLM.1 Modelo lineal en los parámetros
- RLM.2 Muestreo aleatorio
- RLM.3 Media condicionada nula:  $\longrightarrow$
- RLM.4 No multicolinealidad perfecta

$$\begin{cases} E(\varepsilon_i | x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}) = E(\varepsilon_i) \\ E(\varepsilon_i) = 0 \end{cases} \quad \forall i = 1, \dots, N$$

(“RLM”=Regresión Lineal Múltiple)

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- RLM.1 Modelo lineal en los parámetros

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$$

Supuesto bastante flexible: permite usar funciones de las variables de interés

Ejemplo:

$$\log(\text{salario}) = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{exper} + \beta_3 \text{exper}^2 + \varepsilon$$

¿Cómo se interpretan los coeficientes de este ejemplo?

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- RLM.2 Muestreo aleatorio

Los datos necesarios para estimar el modelo se han obtenido por muestreo aleatorio

$$y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad i = 1, \dots, N$$

Por tanto, los datos y el error de la observación “i” y de la observación “h” son independientes

$$\Rightarrow \text{cov}(\varepsilon_i, \varepsilon_h) = 0 \quad \forall i \neq h \text{ con } i, h = 1, \dots, N$$

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- RLM.3 Media condicionada nula

El valor esperado del error, condicionado a las explicativas, es igual al valor esperado no condicionado, y vale cero

$$\left\{ \begin{array}{l} E(\varepsilon_i | x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}) = E(\varepsilon_i) \quad \forall i = 1, \dots, N \quad (\text{RLM.3a}) \\ E(\varepsilon_i) = 0 \quad \forall i = 1, \dots, N \quad (\text{RLM.3b}) \end{array} \right.$$

□ (RLM.3a)  $\equiv$  **exogeneidad estricta**

$\Rightarrow \varepsilon_i$  incorrelacionado con las N observaciones de cada una de las explicativas

□ (RLM.3b)  $\equiv$  **media nula**

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- **exogeneidad débil :**

$$E(\varepsilon_i | x_{1i}, x_{2i}, \dots, x_{ki}) = E(\varepsilon_i) \quad \forall i \text{ con } i = 1, \dots, N$$

$\Rightarrow \varepsilon_i$  incorrelacionado con la observación  $i$ -ésima de cada una de las explicativas

- Con muestreo aleatorio, exogeneidad débil  $\Rightarrow$  exogeneidad estricta

Por tanto:

<ul style="list-style-type: none"><li>▫ RLM.2</li><li>▫ Exogeneidad débil</li><li>▫ RLM.3b</li></ul>	$\Rightarrow$	RLM.3
--	---------------	-------

- Si no hay exogeneidad débil, por lo menos una explicativa  $x_{ji}$ , está correlacionada con  $\varepsilon_i$ , y esta variable explicativa es **endógena**.

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- RLM.4 No multicolinealidad exacta

En la muestra ninguna de las variables explicativas es constante, y no existen relaciones lineales exactas entre las explicativas

- se refiere *sólo* a las variables explicativas en la muestra.
- No excluye cierta correlación *-no perfecta-* entre las explicativas

¿Puede cumplirse el supuesto RLM.4 en este ejemplo?

$$\log(\text{salario}) = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{exper} + \beta_3 \text{exper}^2 + \varepsilon$$



# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- Si hay multicolinealidad exacta, **no es posible obtener el estimador MCO** porque **no está bien definido**

- ¿Por qué?

Ejemplo:  $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^N r_{1i} y_i}{\sum_{i=1}^N r_{1i}^2}$$

donde  $r_{1i}$  = residuo de regresar  $x_1$  sobre  $x_2$ , y un término constante  
es la parte de  $x_1$  no relacionada con  $x_2$

pero si  $x_{1i} = kx_{2i}$  (multicolinealidad exacta):  $r_{1i} = 0 \forall i$

- En general, la multicolinealidad exacta se debe a un error del analista

# 1. El valor esperado del estimador MCO

## 1.1 Supuestos necesarios para la insesgadez

- **Teorema de insesgadez**

Bajo los supuestos RLM.1 a RLM.4,

$$E\left(\hat{\beta}_j / x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}\right) = \beta_j, j = 0, 1, \dots, k$$

para cualquiera de los valores del coeficiente poblacional.

- Los estimadores MCO son estimadores insesgados de los coeficientes poblacionales
- No se puede hablar de la insesgadez de una estimación, sino del estimador.
- Demostración: Wooldridge p. 54 para modelo de regresión simple

Nota: Todas las esperanzas y varianzas están condicionadas a los valores muestrales de las variables explicativas, pero para simplificar notación en las ecuaciones del resto del tema no aparece dicha condición, salvo cuando sea útil.

# 1. El valor esperado del estimador MCO

## 1.2 Errores de especificación e insesgadez del MCO

- Dos tipos frecuentes de error de especificación:
  - **Inclusión de irrelevantes:**  
una (o más) variable(s) explicativa(s) incluida(s) no tiene(n) ningún efecto sobre la variable dependiente del modelo => modelo sobreespecificado
  - **Omisión de relevantes:**  
se omite una (o más) variable(s) explicativa(s) que sí tiene(n) efecto sobre la variable dependiente del modelo => modelo subespecificado
- Tienen efectos distintos sobre la insesgadez

# 1. El valor esperado del estimador MCO

## 1.2 Errores de especificación e insesgadez del MCO

- Efecto de la inclusión de irrelevantes:

modelo verdadero:  $y_i = \beta_0 + \beta_1 x_{1i} + \varepsilon_i$ , cumple RLM.1-RLM.4

modelo planteado:  $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i \Rightarrow \beta_2 = 0$

modelo estimado:  $\tilde{y}_i = \tilde{\beta}_0 + \tilde{\beta}_1 x_{1i} + \tilde{\beta}_2 x_{2i}$

- Se siguen cumpliendo RLM.1-RLM.4  $\Rightarrow E(\tilde{\beta}_j) = \beta_j \quad \forall j = 0, 1, 2 \quad \forall \beta_j$

$$\Rightarrow \begin{cases} E(\tilde{\beta}_0) = \beta_0 \\ E(\tilde{\beta}_1) = \beta_1 \\ E(\tilde{\beta}_2) = \beta_2 = 0 \end{cases}$$

➔ la inclusión de irrelevantes no afecta a la insesgadez

# 1. El valor esperado del estimador MCO

## 1.2 Errores de especificación e insesgadez del MCO

- Efecto de la omisión de relevantes:

modelo verdadero:  $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i$ ,  $\beta_2 \neq 0$ , cumple RLM.1-RLM.4

modelo planteado:  $y_i = \beta_0 + \beta_1 x_{1i} + v_i \Rightarrow v_i = \beta_2 x_{2i} + \varepsilon_i$ , puede fallar RLM.3

modelo estimado:  $\tilde{y}_i = \tilde{\beta}_0 + \tilde{\beta}_1 x_{1i}$

- Usando el modelo *verdadero*,  $E(\hat{\beta}_1) = \beta_1$
- Pero con el modelo mal especificado:

$$E(\tilde{\beta}_1) = \beta_1 + \beta_2 \frac{\sum_{i=1}^N (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sum_{i=1}^N (x_{1i} - \bar{x}_1)^2}$$

**Sesgo de mala especificación**, función de:

- $\beta_2$
- cov. muestral entre  $x_1$  y  $x_2$  (si no es cero, falla RLM.3)

# 1. El valor esperado del estimador MCO

## 1.2 Errores de especificación e insesgadez del MCO

- ¿Por qué?

$$\tilde{\beta}_1 = \frac{\sum (x_{1i} - \bar{x}_1)(y_i - \bar{y})}{\sum (x_{1i} - \bar{x}_1)^2} = \frac{\sum (x_{1i} - \bar{x}_1)(\beta_1(x_{1i} - \bar{x}_1) + \beta_2(x_{2i} - \bar{x}_2) + (\epsilon_i - \bar{\epsilon}))}{\sum (x_{1i} - \bar{x}_1)^2}$$

$$= \beta_1 + \beta_2 \frac{\sum (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sum (x_{1i} - \bar{x}_1)^2} + \frac{\sum (x_{1i} - \bar{x}_1)(\epsilon_i - \bar{\epsilon})}{\sum (x_{1i} - \bar{x}_1)^2}$$

$$E(\tilde{\beta}_1) = E \left[ \beta_1 + \beta_2 \frac{\sum (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sum (x_{1i} - \bar{x}_1)^2} + \frac{\sum (x_{1i} - \bar{x}_1)(\epsilon_i - \bar{\epsilon})}{\sum (x_{1i} - \bar{x}_1)^2} \right] =$$

$$= \beta_1 + \beta_2 \frac{\sum (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sum (x_{1i} - \bar{x}_1)^2}$$

- No sólo es importante el signo del sesgo sino también el tamaño del mismo.

# 1. El valor esperado del estimador MCO

## 1.2 Errores de especificación e insesgadez del MCO

- Ejemplo: salario en función del nivel de estudios y de la habilidad

Modelo verdadero (estimado):  $s\hat{a}l_i = \hat{\beta}_0 + \hat{\beta}_1 ne_i + \hat{\beta}_2 habil_i$

Modelo planteado (estimado):  $s\tilde{a}l_i = \tilde{\beta}_0 + \tilde{\beta}_1 ne_i$

➔ 
$$\text{Sesgo}(\tilde{\beta}_1) = \beta_2 \frac{\sum (ne_i - \bar{ne})(habil_i - \bar{habil})}{\sum (ne_i - \bar{ne})^2}$$

- Es probable que  $Cov(ne, habil) > 0$  y también  $\beta_1 > 0, \beta_2 > 0$
- Por tanto:
  - Sobreestimación de  $\beta_1$
  - Sobrevaloración del impacto de  $ne$  sobre  $sal$

## 2. La varianza del estimador MCO y su estimación

### 2.1 La varianza del estimador MCO

- Necesitamos una medida de la **dispersión** de  $\hat{\beta}_j$  alrededor del valor central  $E(\hat{\beta}_j)$ :  $V(\hat{\beta}_j)$

- $V(\hat{\beta}_j)$  depende de las características del modelo.

- Característica más simple: Supuesto RLM.5: homoscedasticidad

$$V(\varepsilon_i | x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}) = V(\varepsilon_i) = \sigma^2 \quad \forall i = 1, \dots, N$$

$$\Rightarrow V(y_i | x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}) = V(\varepsilon_i | x_{11}, x_{21}, \dots, x_{(k-1)N}, x_{kN}) = \sigma^2 \quad \forall i$$

La varianza del error ( y por tanto de  $y$ ) es independiente de los valores de las explicativas, y además es constante.

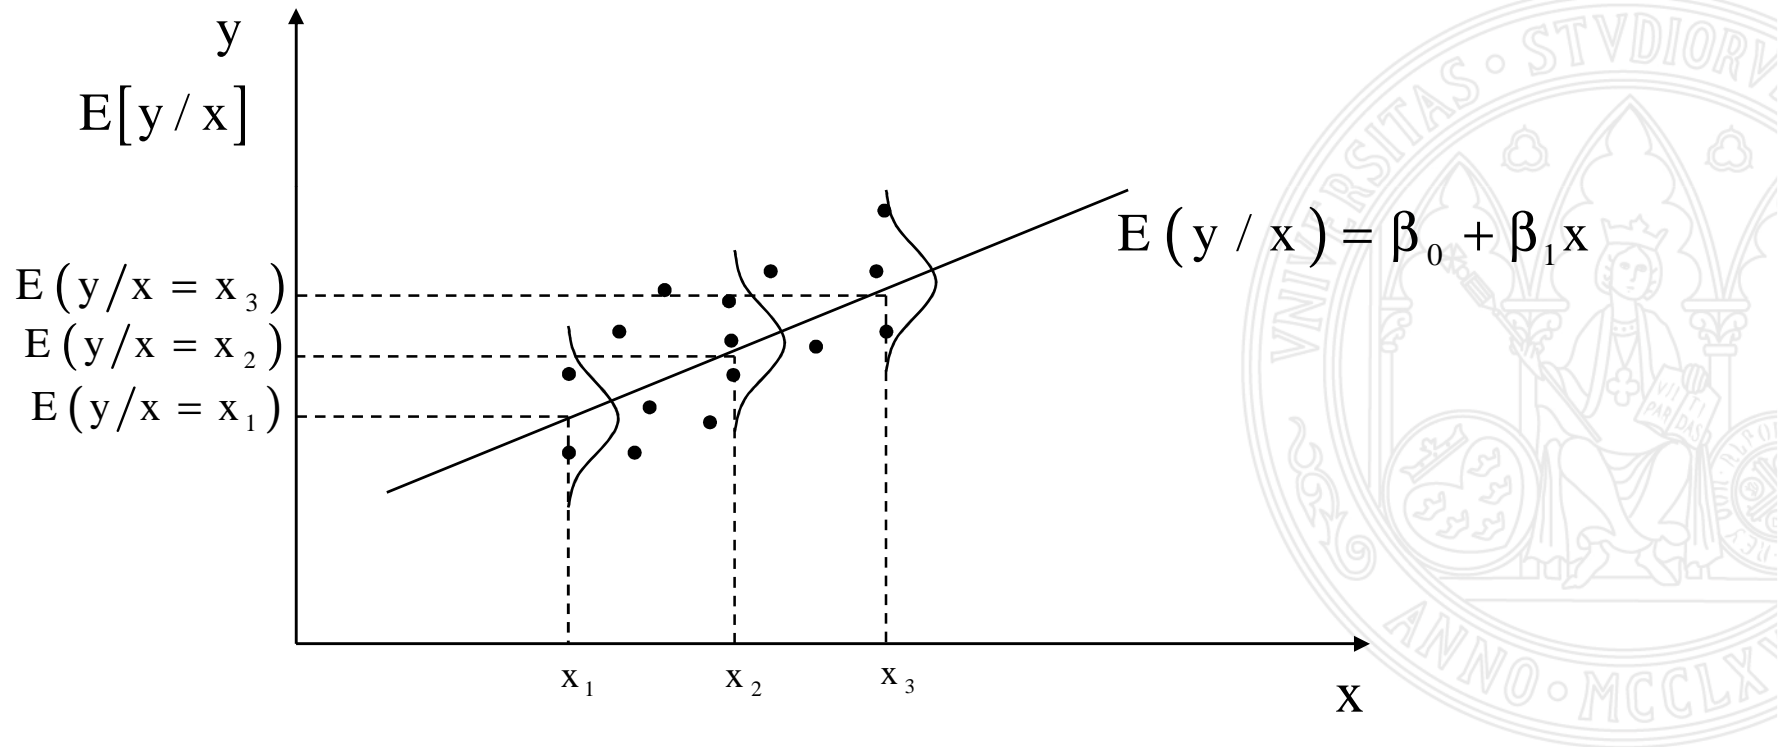
 homoscedasticidad  $\equiv$  “la varianza del error es constante “



## 2. La varianza del estimador MCO y su estimación

### 2.1 La varianza del estimador MCO


- Homoscedasticidad:



## 2. La varianza del estimador MCO y su estimación

### 2.1 La varianza del estimador MCO

- Heteroscedasticidad:



## 2. La varianza del estimador MCO y su estimación

### 2.1 La varianza del estimador MCO

- **Teorema de las varianzas muestrales de los estimadores MCO de los coeficientes de los regresores:**

Bajo RLM.1 a RLM.5, condicionando a los valores muestrales de las variables explicativas,

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

$$STC_j = \sum_{i=1}^N (x_{ji} - \bar{x}_j)^2, \text{ proporcional a la varianza muestral de } x_j$$

$R_j^2$  = R-cuadrado de la regresión de  $x_j$  sobre el resto de explicativas y un término constante

## 2. La varianza del estimador MCO y su estimación

### 2.1 La varianza del estimador MCO

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

Tres componentes:

- varianza del error  $\sigma^2$ : a mayor  $\sigma^2$ , mayor  $V(\hat{\beta}_j)$   
 $\sigma^2$  grande, muestra más dispersa  $\Rightarrow$  estimación menos precisa de las pendientes
- variación muestral de  $x_j$ : a mayor  $STC_j$ , menor  $V(\hat{\beta}_j)$   
 $x_j$  varía mucho  $\Rightarrow$  más fácil capturar con precisión el efecto ceteris paribus de sus variaciones sobre  $y$
- relación de  $x_j$  con las demás explicativas: a menor  $R_j^2$ , menor  $V(\hat{\beta}_j)$   
 $x_j$  muy relacionado con el resto de explicativas  $\Rightarrow$  más difícil capturar con precisión el efecto ceteris paribus de sus variaciones sobre  $y$

## 2. La varianza del estimador MCO y su estimación

### 2.2 Multicolinealidad fuerte y varianzas MCO

- **Multicolinealidad fuerte** ( o multicolinealidad)  
existe una correlación alta (no exacta) entre dos o más variables explicativas
  - No viola ninguno de los supuestos RLM.1 a RLM.5 😊
  - Pero genera valores altos de varios  $R_j^2 \Rightarrow$  varias  $V(\hat{\beta}_j)$  (muy) altas
- ➡ fuente de **(mucho) imprecisión en las estimaciones** 😞
- ¿cómo detectarla? ¿soluciones posibles?

## 2. La varianza del estimador MCO y su estimación

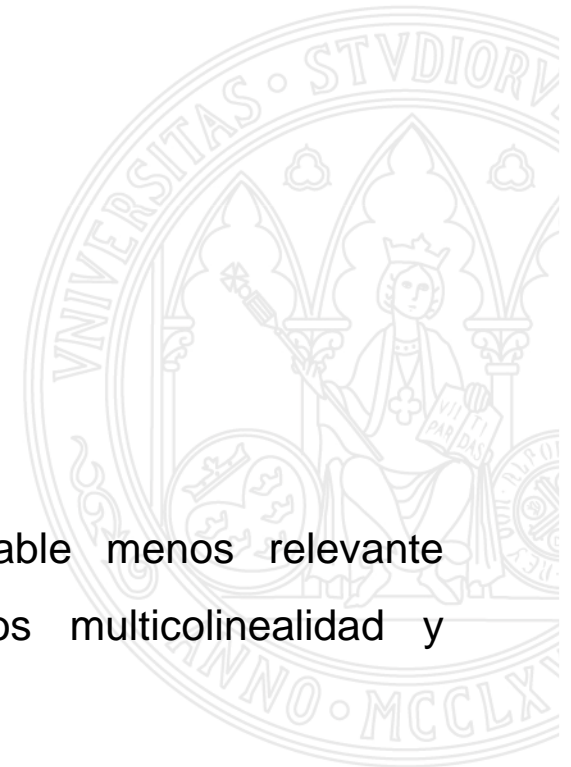
### 2.2 Multicolinealidad fuerte y varianzas MCO

- **Para detectarla:**

- Si es entre 2 variables explicativas
  - Coeficiente de correlación lineal
  - Diagrama de dispersión
- Si es entre más de dos variables explicativas
  - los  $R_j^2$   $j=1,2,\dots,k$

- **Para solucionarla:**

- Recoger más datos (aumentar N)
- Si no es posible, reducirla eliminando alguna variable menos relevante (problema: ¿cuál es “menos relevante”? ¿reducimos multicolinealidad y dispersión a costa de introducir sesgo? (Ver tema4)



## 2. La varianza del estimador MCO y su estimación

### 2.3 El estimador de la varianza del estimador MCO

$$V(\hat{\beta}_j) = \frac{\sigma^2}{STC_j(1-R_j^2)}$$

→ desconocido (for  $\sigma^2$ )  
→ calculable (for  $STC_j(1-R_j^2)$ )

- Necesitamos un estimador insesgado de  $\sigma^2 = E(\varepsilon_i^2)$
- Bajo RLM.1 - RLM.5 (demostración: Wooldridge p.62 para modelo de regresión simple)

$$s^2 = \frac{\sum_{i=1}^N e_i^2}{N-K} \quad \text{con } E(s^2) = \sigma^2$$

→ estimador insesgado de  $V(\hat{\beta}_j)$ :  $\hat{V}(\hat{\beta}_j) = \frac{s^2}{STC_j(1-R_j^2)}$

## 2. La varianza del estimador MCO y su estimación

### 2.4 Varianzas en modelos mal especificados

- Inclusión de irrelevantes:

modelo verdadero:  $y_i = \beta_0 + \beta_1 x_{1i} + \varepsilon_i$ , cumple RLM.1-RLM.5

modelo planteado:  $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i \Rightarrow \beta_2 = 0$

modelo estimado:  $\tilde{y}_i = \tilde{\beta}_0 + \tilde{\beta}_1 x_{1i} + \tilde{\beta}_2 x_{2i}$

$$V(\hat{\beta}_1) = \frac{\sigma^2}{STC_1} \text{ en mod. verdadero}$$

$$\text{pero } V(\tilde{\beta}_1) = \frac{\sigma^2}{STC_1(1-R_1^2)} \text{ en mod. estimado}$$

- ➔ las varianzas aumentan
- ➔ se pierde precisión en la estimación



## 2. La varianza del estimador MCO y su estimación

### 2.4 Varianzas en modelos mal especificados

- Omisión de relevantes:

modelo verdadero:  $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i$ ,  $\beta_2 \neq 0$ , cumple RLM.1-RLM.5

modelo planteado:  $y_i = \beta_0 + \beta_1 x_{1i} + v_i \Rightarrow v_i = \beta_2 x_{2i} + \varepsilon_i$  pero se ignora

modelo estimado:  $\tilde{y}_i = \tilde{\beta}_0 + \tilde{\beta}_1 x_{1i}$

$$\hat{V}(\hat{\beta}_1) = \frac{s^2}{STC_1(1-R_1^2)}$$

pero  $\hat{V}(\tilde{\beta}_1) = \frac{s_v^2}{STC_1}$

- ➔ las varianzas estimadas podrían reducirse
- ➔ mayor precisión aparente en la estimación

### 3. Optimalidad de MCO

#### 3.1 Supuestos necesarios

- Hasta ahora, hemos visto:
  - RLM.1-RLM.4: necesarios para la insesgadez de MCO
  - RLM.1-RLM.5: necesarios para la fórmula de  $V(\hat{\beta}_j)$

- RLM.1-RLM.5 = “supuestos de Gauss-Markov”
- Garantizan la **optimalidad** del estimador MCO.

Recordemos: “estimador óptimo”  $\equiv$  estimador de mínima varianza dentro de una clase concreta

### 3. Optimalidad de MCO

#### 3.2 Teorema de Gauss-Markov

- Teorema de Gauss-Markov:

Bajo los supuestos RLM.1-RLM.5,  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  son los **estimadores lineales insesgados óptimos (ELIO)** de  $\beta_0, \beta_1, \dots, \beta_k$ , respectivamente.


- Interpretación:

- RLM.1-RLM.5 garantizan que el MCO es el estimador más preciso de entre todos los estimadores lineales e insesgados.
- Si falla un supuesto de RLM.1 a RLM.4 (p.ej. RLM.3 que suele fallar), deja de ser insesgado.
- Si falla RLM.5, existe otro estimador más preciso (ver Tema 6)

## 4. Consistencia del estimador MCO

### 4.1 Introducción

- No siempre se cumplen RLM.1-RLM.4 que aseguran insesgadez del MCO (*propiedad de muestra finita*)
- Pero un estimador debe ser por lo menos **consistente**: a mayor tamaño muestral, menos probabilidad de que el estimador se aleje del valor poblacional (*propiedad asintótica*)



Tamaño muestral :  
 $T_1 < T_2 < \dots < T_\infty$   
Valor poblacional: 4

## 4. Consistencia del estimador MCO

### 4.2 Supuestos necesarios

- Bajo RLM.1-RLM.4, MCO es insesgado y **consistente**:

$$E(\hat{\beta}_j) = \beta_j \quad \text{y también} \quad \underset{N \rightarrow \infty}{\text{plim}}(\hat{\beta}_j) = \beta_j$$

(dem. Consistencia Wooldridge p. 183)

- Puede fallar la exogeneidad estricta. Entonces, MCO está sesgado.
- Pero con supuestos más débiles, garantizamos por lo menos la consistencia.

- RLM.3'**:

$$\begin{cases} E(\varepsilon_i | x_{1i}, x_{2i}, \dots, x_{ki}) = E(\varepsilon_i) & \forall i = 1, \dots, i, \dots, N & \text{(RLM.3a')} \\ E(\varepsilon_i) = 0 & i = 1, \dots, N & \text{(RLM.3b)} \end{cases}$$

RLM.3a' : exogeneidad débil

## 4. Consistencia del estimador MCO

### 4.3 Teorema

- **Teorema de consistencia del estimador MCO:**  
Bajo los supuestos RLM.1, RLM.3' y RLM.4,

$$\text{plim}_{N \rightarrow \infty}(\hat{\beta}_j) = \beta_j$$

- No hace falta RLM.2
- La validez práctica de este resultado requiere un tamaño muestral grande
- Nota: con sólo exogeneidad débil, el estimador MCO está sesgado y deja de ser ELIO, y las fórmulas de las varianzas utilizadas ya no sirven.

# Lo que hemos aprendido:

## 1. Propiedades de muestra finita del MCO:

- Supuestos mínimos que garantizan la insesgadez del MCO

*Linealidad en los parámetros, muestreo aleatorio, exogeneidad estricta, no multicolinealidad exacta.*

- Efectos de la mala especificación sobre la insesgadez:

- *Incluir una irrelevante no sesga la estimación MCO*
- *Omitir una relevante sesga la estimación, y el sesgo es mayor cuanto más relacionada esté la omitida con las incluidas*

## Lo que hemos aprendido:

- Varianza del estimador MCO, bajo homoscedasticidad y los supuestos de insesgadez
- Cómo estimar esta varianza
- Cómo afecta la multicolinealidad fuerte a la precisión de las estimaciones
- Cómo la inclusión de irrelevantes y la omisión de relevantes afectan a la precisión de la estimación
- Los supuestos para que MCO sea óptimo (ELIO)

## 2. Propiedad asintótica del MCO:

- Unos supuestos menos exigentes, para que MCO sea al menos consistente: *exogeneidad débil*