

INTRODUCCIÓN A LA ECONOMETRÍA

3er curso LE y LADE

Tema 2c

Dpto. de Econometría y Estadística (EA3)

UPV—EHU

2.7a Omisión de variables relevantes.

Omisión de variables relevantes

- **relación verdadera:**

$$Y = X\beta + u = \begin{bmatrix} X_I & | & X_{II} \end{bmatrix} \begin{pmatrix} \beta_I \\ \beta_{II} \end{pmatrix} + u$$

$$X = \begin{bmatrix} 1 & X_{11} & \dots & X_{K_1,1} & | & X_{K_1+1,1} & \dots & X_{K_1} \\ 1 & X_{12} & \dots & X_{K_1,2} & | & X_{K_1+1,2} & \dots & X_{K_2} \\ \dots & \dots & \dots & \dots & | & \dots & \dots & \dots \\ 1 & X_{1T} & \dots & X_{K_1,T} & | & X_{K_1+1,T} & \dots & X_{KT} \end{bmatrix}, \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_{K_1} \\ \hline \beta_{K_1+1} \\ \vdots \\ \beta_K \end{pmatrix}$$

$$Y = X_I\beta_I + X_{II}\beta_{II} + u$$

- **relación estimada :**

$$Y = X_I\beta_I + v \quad \text{donde } v = X_{II}\beta_{II} + u,$$

$$\text{entonces } E(v) \neq 0 \quad \rightsquigarrow \quad E(\hat{\beta}) \neq \beta.$$

es decir $\hat{\beta}$ es **sesgado**.

Omisión de variables relevantes: consecuencias

Resumen:

- Estimador MCO de los **coeficientes** es **sesgado** (excepto si $x_I'x_{II} = 0$).
- Estimador MCO del **intercepto** es **siempre sesgado**.
- Estimador de **varianza del error** es **siempre sesgado**.

2.7b Multicolinealidad

Multicolinealidad Perfecta

Caso extremo:

- combinación lineal **exacta**:

- $\sum_{k=0}^K \lambda_k X_{kt} = 0, \quad \lambda \neq 0, \quad X_{0t} = 1,$

- $\exists X_i \mid X_i = \lambda_0^* + \sum_{\substack{k=1 \\ k \neq i}}^K \lambda_k^* X_{kt},$

- $\exists X_i, X_j \mid \text{Corr}(X_i, X_j) = 1,$

- $\exists X_i \mid \text{regres aux } X_i \text{ sobre } \{X_k\}_{\substack{k=1 \\ k \neq i}}^K \rightsquigarrow R_i^2 = 1.$

- Problema:

- $\text{rk } X < K+1, \text{ (} X \text{ no es de rango completo)}$

- $\rightsquigarrow \det(X) = 0$

- $\rightsquigarrow \nexists (X'X)^{-1}$

- \rightsquigarrow

$\hat{\beta}$?

Multicolinealidad perfecta: ejemplo

- Sea $X_{4t} = 2X_{1t} \quad \forall t:$

$$X_{4t} = 0 + 2X_{1t} + 0 \cdot X_{2t} + 0 \cdot X_{3t} + 0 \cdot X_{5t} + \dots + 0 \cdot X_{Kt},$$

- ¿no error?** \Rightarrow regres aux X_4 sobre $\{X_k\}_{\substack{k=1 \\ k \neq 4}}^K \rightsquigarrow !R_4^2 = 1!!$

- Especificación del modelo:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + \dots + u_t, \quad t = 1, 2, \dots, T,$$

$$X_{4t} = 2X_{1t},$$

- y sustituyendo en el modelo:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 (2X_{1t}) + \dots + u_t,$$

$$= \beta_0 + \underbrace{(\beta_1 + 2\beta_4)}_{\beta_1^*} X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + u_t$$

- ahora tenemos **un parámetro menos** para estimar.

Multicolinealidad: contra-ejemplo

$$Y_t = \beta_0 + \beta_1^* X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + u_t$$

- Sólo quedan K parámetros a estimar,

pero β_1 y β_4 **no se pueden estimar por separado**:

- únicamente podemos estimar una combinación lineal de ellos:

$$\beta_1^* = \beta_1 + 2\beta_4,$$

- es decir **¡efecto combinado** de X_{1t} y X_{4t} sobre Y_t !!

- (Ejercicio: **Pruébese con** $X_{2t} - 3X_{3t} = 10, \quad \forall t.$)

- multicolinealidad = *relaciones lineales*

pero... ¿qué ocurre si **la relación no es lineal?** p.ej.:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{1t}^2 + u_t$$

- X tiene rango completo por columnas \rightsquigarrow **no hay problema.**

Multicolinealidad perfecta : consecuencias

- algunos parámetros no pueden estimarse **por separado**.

- algunas estimaciones son sólo **c.l. de los parámetros**.

- R^2 es **correcto**:

recoge correctamente la proporción de (la varianza de) Y_t explicada por la regresión

- Las predicciones de Y son todavía **validas**.

2.7c Multicolinealidad imperfecta

Multicolinealidad imperfecta

■ Problema:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + \dots + u_t, t = 1, 2, \dots, T,$$

$$X_{4t} = 2X_{1t} + v_t,$$

v_t = discrepancia entre X_{4t} y $2X_{1t}$,

■ relación **aproximada** :

- regresión auxiliar X_{4t} sobre el resto $\rightsquigarrow R^2 \approx 1$.
- es una cuestión de grado ($x'x$ no diagonal \rightsquigarrow variables correlacionadas)

■ Nota: si no se especifica perfecta/imperfecta

quiere decir mc imperfecta.

Multicolinealidad: Síntomas

■ Síntomas típicos :

- ◆ **alto R^2** (grupo relevante de regresores)
- ◆ pero variables parecen **no relevantes** individualmente (incapacidad de separar efectos de regresores).

■ más formalmente:

$$\text{Var}(\hat{\beta}^*) = \sigma^2(x'x)^{-1} = \frac{\sigma^2}{T} \text{Var}(X^*)^{-1}$$

$$\Rightarrow \text{Var}(\hat{\beta}_k) = \frac{\sigma^2}{T \text{Var}(X_k)(1 - R_k^2)},$$

■ de forma que en el ejemplo anterior $X_{4t} \approx 2X_{1t}$:

- ◆ $\text{Corr}(X_4, X_1) \uparrow$
- ◆ R_4^2 y $R_1^2 \uparrow \uparrow$
- ◆ denominador \downarrow
- ◆ **varianzas $\uparrow \uparrow$**

Multicolinealidad: Consecuencias

- Algunos coeficientes **no son significativos**, a pesar de que sus variables tienen un efecto importante sobre la variable dependiente.
- De todas maneras, Gauss-Markov \Rightarrow estimadores lineales, **insesgados** y de **varianza mínima**, entonces **no es posible encontrar un ELI (más) Óptimo**.
- R^2 es **correcto**: recoge correctamente la proporción de (la varianza de) Y_t explicado por la regresión.
- Predicciones de Y son todavía **validas**.

Multilinealidad: Como detectar

- **Pequeños cambios** en los datos
⇒ importantes **cambios** en las estimaciones
(pueden afectar hasta sus signos).
- Estimaciones de los **coeficientes**
no son significativas de forma **individual**...
- ... pero sí lo son de forma **conjunta**.
- **Alto** coeficiente de determinación R^2 .
- **Regresiones auxiliares** entre regresores
⇒ **alto** R_k^2 .

Multilinealidad: Algunas soluciones

La multilinealidad no es un **problema fácil** de solucionar.
De todas formas, de

$$\text{Var}(\hat{\beta}_k) = \frac{\sigma^2}{T\text{Var}(X_k)(1 - R_k^2)},$$

tenemos que para reducir la varianza podríamos:

T ↑: Incrementar el número de observaciones T .

También, las diferencias entre regresores pueden incrementar.

Var(X) ↑: Incrementar dispersión de los datos; *p.ej.* estudio sobre la función del consumo:

muestra de familias ↔ todas las rentas posibles.

Var(X) ↑: Incluir información adicional.

p.ej. imponer restricciones sugeridas por T^a . Ec.

σ^2 ↓: Añadir un nuevo regresor relevante todavía no incluido.

También evitaría serios problemas de sesgo.

R_k^2 ↓: Eliminar variables que pueden ser causa de la multilinealidad.

(Aunque tener cuidado de no omitir algún regresor relevante).

2.8 Estimador MCO bajo Restricciones.

MRLG bajo restricciones lineales (1)

- objetivos de capítulos **previos**:
 - ◆ Modelo Económico (MRLG), características y supuestos básicos...
 - ◆ pero... **no hay conocimiento** sobre los parámetros del modelo.
 - ◆ El Método Mínimo-Cuadrático de estimación de parámetros (MCO).
 - ◆ Propiedades de los estimadores resultantes.
- objetivos del **presente** capítulo:
 - ◆ **Información a priori** sobre los valores del parámetro (o c.l.) ...
 - ◆ dada por
 - teoría económica,
 - otros trabajos empíricos,
 - experiencia propia, etc.
 - ◆ Modelo No Restringido ⇒ MC Ordinarios.
 - ◆ Modelo Restringido ⇒ MC Restringidos.
 - ◆ **Comprobar**, dado el modelo estimado, si la información es compatible con los datos disponibles.

Estimación: MC Restringidos (cont).

- c.1^{er}o. \rightsquigarrow **ecuaciones normales:**

$$X' \hat{u}_R + R' \hat{\lambda} = 0, \quad (4)$$

$$R \hat{\beta}_R = r, \quad (5)$$

donde $\hat{\beta}_R$ y $\hat{\lambda}$ son valores de β, λ que satisfacen las c.1^{er}o. y los residuos

$$\hat{u}_R = Y - X \hat{\beta}_R. \quad (6)$$

- **Despejando** $\hat{\beta}_R$ y $\hat{\lambda}$:

$$\begin{aligned} \hat{\lambda} &= [R(X'X)^{-1}R']^{-1}(r - R\hat{\beta}), \\ \hat{\beta}_R &= \hat{\beta} + (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(r - R\hat{\beta}) \\ &= \hat{\beta} + A(r - R\hat{\beta}) = (I - AR)\hat{\beta} + Ar \end{aligned} \quad (7)$$

donde $A = (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}$.

Estimación MCR: características

- Expresión (7): $\hat{\beta}_R = \hat{\beta} + A(r - R\hat{\beta}) \rightsquigarrow$
 - ◆ la estimación restringida $\hat{\beta}_R$ puede obtenerse como una función de la estimación ordinaria (no restringida): $\hat{\beta}$
 - ◆ $R\hat{\beta} \simeq r \Rightarrow \hat{\beta}_R$ (restringido) $\simeq \hat{\beta}$ (no restringido).
- <2>Ecuaciones normales (4): $X' \hat{u}_R + R' \hat{\lambda} = 0 \rightsquigarrow$
 - ◆ se satisfacen las restricciones (obvio).
 - ◆ $X' \hat{u}_R \neq 0$, es decir:
 - suma de residuos restringidos no es cero,
 - residuos restringidos no ortogonales a las variables explicativas,
 - entonces, residuos restringidos no ortogonales a \hat{Y}_R ajustado.
 - ◆ **SCT \neq SCR_R + SCE_R**
(compárese con caso ordinario y con ecuación transformada: ¿R² ??).

Propiedades del estimador MCR (1)

Expresión (7) : $\hat{\beta}_R = (I - AR)\hat{\beta} + Ar \rightsquigarrow$

1. **Lineal:** estimador MCR $\hat{\beta}_R$ es c.l. del estimador MCO $\hat{\beta}$, que es lineal, luego, a su vez, $\hat{\beta}_R$ es también lineal

2. **Sesgo:** estimador MCR $\hat{\beta}_R$ es $\begin{cases} \text{sesgado,} & \text{si } R\beta \neq r, \\ \text{insesgado,} & \text{si } R\beta = r \text{ cierto} \end{cases}$

Demo:

$$E(\hat{\beta}_R) = (I - AR)E(\hat{\beta}) + Ar = (I - AR)\beta + Ar = \beta + A(r - R\beta).$$

3. **Matriz de Covarianzas:** $\text{Var}(\hat{\beta}_R) = (I - AR)\text{Var}(\hat{\beta}) = \sigma^2(I - AR)(X'X)^{-1}$

Demo: (ver apuntes o libro de texto)

Propiedades del estimador MCR (2)

4. **Varianza menor** que los estimadores MCO, aunque las restricciones **no sean ciertas:**

Demo:

$$\begin{aligned} \text{Var}(\hat{\beta}_R) &= \text{Var}(\hat{\beta}) - AR \text{Var}(\hat{\beta}) \\ &= \text{Var}(\hat{\beta}) - (\text{matriz psd}). \end{aligned}$$

□

5. resultado sorprendente (aparentemente):
 - menos "incertidumbre" sobre parámetros \rightsquigarrow más precisión en estimación...
 - pero... hacia un resultado erróneo (sesgado) si la restricción no es cierta.

Multicolinealidad frente a restricciones

Es importante **distinguir claramente** entre dos casos diferentes:

- relaciones lineales **entre regresores**

(es decir multicolinealidad):

p.ej. $X_{4t} = 2X_{1t}$

⇒ falta información para estimaciones individuales.

- relaciones lineales **entre coeficientes:**

p.ej. $\beta_4 = 2\beta_1$

⇒ información extra sobre parámetros

↪ estimadores con varianza más pequeña.

- modelos a estimar respectivamente:

$$Y_t = \beta_0 + \underbrace{(\beta_1 + 2\beta_4)}_{\beta_1^*} X_{1t} + \beta_2 X_{2t} + \dots + u_t,$$

$\Rightarrow \hat{\beta}_1^*$ pero ¿ $\hat{\beta}_1, \hat{\beta}_4$?

$$Y_t = \beta_0 + \beta_1 \underbrace{(X_{1t} + 2X_{4t})}_{X_{1t}^*} + \beta_2 X_{2t} + \dots + u_t,$$

$\Rightarrow \hat{\beta}_1$ y $\hat{\beta}_4 = 2\hat{\beta}_1$