

εσταδιστιχ̄

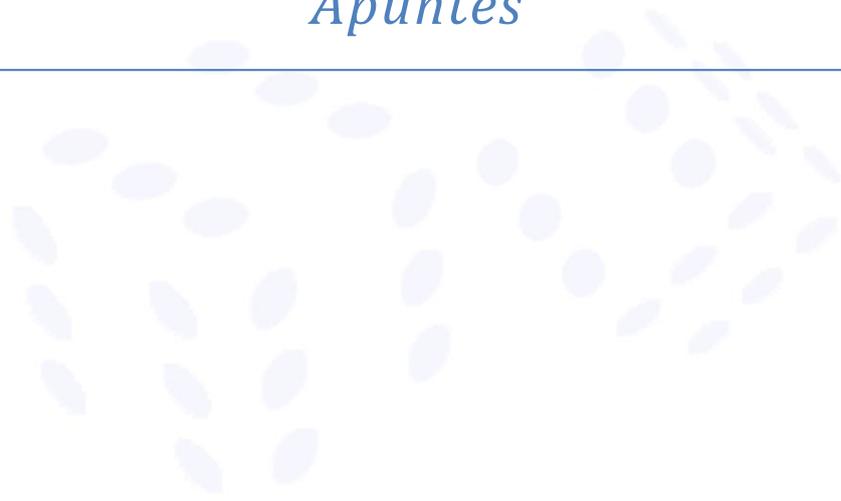
εσταδιστιχ̄

Econometría II

Grado en Economía UB

ESTADISTIX

Apuntes



0. REPASO ECONOMETRÍA I

EL MODELO DE REGRESIÓN LINEAL MÚLTIPLE

Notación algebraica $y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + \dots + \beta_k x_{ki} + u_i \quad i = 1, 2 \dots n$

Notación matricial $Y = X\beta + u$

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{21} & \dots & x_{k1} \\ 1 & x_{22} & & x_{k2} \\ \vdots & \vdots & & \vdots \\ 1 & x_{2n} & & x_{kn} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

$$\hat{\beta}_{MQO} = (X'X)^{-1}(X'Y) \quad \text{Var}(\hat{\beta}) = \sigma^2(X'X)^{-1}$$

Modelo poblacional

$$y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + \dots + \beta_k x_{ki} + u_i$$

Modelo muestral

$$y_i = \hat{\beta}_1 + \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i} + \dots + \hat{\beta}_k x_{ki} + \hat{u}_i$$

Error de predicción (residual, error o perturbación): $\hat{u}_i = e_i = y_i - \hat{y}_i$

Bondad de ajuste

$$R^2 = \frac{SCR}{SCT} = 1 - \frac{SCE}{SCT} \quad \tilde{R}^2 = 1 - \left[\frac{N-1}{N-k} \cdot (1 - R^2) \right]$$

SUPUESTOS GENERALES DEL MODELO

- La relación entre las exógenas, la endógena y el término de perturbación debe ser **lineal**.
- Las variables explicativas (x) son independientes del término de perturbación: **E(u | x) = 0**.
- Las variables x **no presentan errores** de medida
- El número de observaciones n debe ser igual o mayor que el número de regresores: **n ≥ k**
- Cada regresor debe ser linealmente independiente de los demás, no puede haber **multicolinealidad**
- Los parámetros β_i **son fijos** y deterministas (no aleatorios)
- No hay omisión de variables relevantes ni inclusión de variables irrelevantes

Supuestos del término de perturbación

- La perturbación uno tiene esperanza de 0 y sigue una **normal** independientemente distribuida

$$u \sim N(0, \sigma^2 \cdot Id) \quad E(u) = 0$$

- La perturbación uno tiene una varianza constante (supuesto de **homocedasticidad**)

$$\text{Var}(u) = \sigma^2$$

- La perturbación u es aleatoria, no presenta **autocorrelación**. $\text{Cov}(u_i, u_j) = 0$

INTERPRETACIÓN ECONÓMICA DE LOS PARÁMETROS

Interpretaciones de los coeficientes en las diferentes formas funcionales:

1. $\hat{y}_i = \hat{\beta}_1 + \hat{\beta}_2 x_i$ el coef. $\hat{\beta}_2$ nos indica el cambio medio esperado en y por cada unidad de x .
2. $\hat{y}_i = \hat{\beta}_1 + \hat{\beta}_2 \ln(x_i)$ el coef. $\hat{\beta}_2$ nos indica que si $x \uparrow 1\%$, esperamos que y aumente en $\frac{\hat{\beta}_2}{100}$ unidades
3. $\ln(\hat{y}_i) = \hat{\beta}_1 + \hat{\beta}_2 x_i$ el coef. $\hat{\beta}_2$ nos indica que si $x \uparrow 1u$, esperamos que y aumente en $100 \cdot \hat{\beta}_2 \%$
4. $\ln(\hat{y}_i) = \hat{\beta}_1 + \hat{\beta}_2 \ln(x_i)$ el coef. $\hat{\beta}_2$ nos indica que si $x \uparrow 1\%$, esperamos que y aumente en $\hat{\beta}_2 \%$

DISTRIBUCIÓN DEL ESTIMADOR MCO Y PROPIEDADES

No sesgo: la esperanza del estimador es su parámetro $E(\hat{\beta}_i) = \beta_i$

Eficiencia: la varianza del estimador es la mínima posible: $var(\hat{\beta}_{MCO}) < var(\hat{\beta}_i)$

Consistencia: la estimación mejora al aumentar los datos $\lim_{n \rightarrow \infty} (\hat{\beta}_i) = \beta_i$

Inferència sobre dels paràmetres del model

Intervalo de confianza $P\left(\hat{\beta}_j - ee(\hat{\beta}_j) \cdot t_{n-k} < \beta_j < \hat{\beta}_j + ee(\hat{\beta}_j) \cdot t_{n-k}\right) = 1 - \alpha$

Contraste de significación individual $\begin{cases} H_0 \beta_j = 0 \\ H_A \beta_j \neq 0 \end{cases} EC = \frac{\hat{\beta}_j}{ee(\hat{\beta}_j)} \sim t_{n-k} \rightarrow pv$

Contraste de significación global $\begin{cases} H_0 \beta_2 = \beta_3 = \dots = 0 \\ H_A \text{ No } H_0 \end{cases} EC = \frac{R^2}{\frac{1-R^2}{n-k}} = \sim F_{k-1, n-k} \rightarrow pv$

Ejemplo Gretl:

Modelo 2: MCO, usando las observaciones 1-35
Variable dependiente: Notas_final

	coeficiente	Desv. típica	Estadístico t	valor p
const	0.537561	2.67569	0.2009	0.8421
Edad	0.0156761	0.102044	0.1536	0.8789
Academia	3.38150	0.659482	5.128	1.49e-05 ***
Asistencia	0.0356565	0.0398292	0.8952	0.3776
Media de la vble. dep.	6.057143	D.T. de la vble. dep.	2.472708	
Suma de cuad. residuos	107.2981	D.T. de la regresión	1.860438	
R-cuadrado	0.483860	R-cuadrado corregido	0.433911	
F(3, 31)	9.687085	Valor p (de F)	0.000115	
Log-verosimilitud	-69.26745	Criterio de Akaike	146.5349	
Criterio de Schwarz	152.7563	Crit. de Hannan-Quinn	148.6825	

1. VARIABLES EXPLICATIVAS ENDÓGENAS

INTRODUCCIÓN

Bajo el cumplimiento de las hipótesis básicas, los estimadores por MCO son no sesgados, consistentes y eficientes. Una hipótesis que podría incumplirse es la de que las **variables explicativas no deben estar correlacionadas con el término de perturbación**.

$$E(x_i, u_i) = E(X'U) = 0 \quad \text{Variables explicativas exógenas}$$

$$E(x_i, u_i) = E(X'U) \neq 0 \quad \text{Variables explicativas endógenas}$$

Si tenemos variables explicativas endógenas tendremos estimadores **inconsistentes (teorema de Mann- Wald)**:

$$E(X'U) \neq 0 \quad \rightarrow \quad p \lim_{N \rightarrow \infty} \left[\frac{1}{N} (X'U) \right] \neq 0 \quad \rightarrow \quad p \lim_{N \rightarrow \infty} \hat{\beta}_{MCO} \neq \beta$$

CAUSAS DE LA CORRELACIÓN ENTRE VARIABLES EXPLICATIVAS (X) Y LA PERTURBACIÓN (U)

1.- Omisión de variable relevante no observable correlacionada con variables del modelo.

$$\text{modelo real} \rightarrow \text{Salario}_i = \beta_1 + \beta_2 \text{educación}_i + \beta_3 \text{capacidad}_i + u_i$$

$$\text{modelo estimado} \rightarrow \text{Salario}_i = \beta_1 + \beta_2 \text{educación}_i + v_i \quad \text{on} \quad v_i = \beta_3 \text{capacidad}_i + u_i$$

2.- Errores de medida a la hora de registrar una de las variables explicativas

$$\text{modelo real} \rightarrow \text{Salario}_i = \beta_1 + \beta_2 \text{experiencia}_i + u_i$$

$$\text{modelo estimado} \rightarrow \text{Salario}_i = \beta_1 + (\beta_2 \text{experiencia}_i + e_i) + v_i$$

$$\text{Salario}_i = \beta_1 + \beta_2 \text{experiencia}_i + \beta_2 e_i + v_i$$

ESTIMACIÓN POR VARIABLES INSTRUMENTALES

Definiremos una **matriz Z** de dimensión $N \times K$ como la matriz de variables instrumentales. Dicha matriz debe cumplir que esté:

- 1.- No correlacionada con el término de error: $E(z_i, u_i) = 0$
- 2.- Correlacionada con las variables de la matriz X: $E(z_i, x_i) \neq 0$

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_T \end{pmatrix} \quad X = \begin{pmatrix} 1 & X_{21} & X_{31} & \cdots & X_{k1} \\ 1 & X_{22} & X_{32} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{2N} & X_{3N} & \cdots & X_{kN} \end{pmatrix} \quad \text{Siguiendo } Z = \begin{pmatrix} 1 & Z_1 & X_{31} & \cdots & X_{k1} \\ 1 & Z_2 & X_{32} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & Z_N & X_{3N} & \cdots & X_{kN} \end{pmatrix}$$

Así, imaginamos un modelo donde la variable x_3 tiene propiedades de endogeneidad:

$$y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + u_i$$

$$X = [1, x_{2i}, x_{3i}] \quad Z = [1, x_{2i}, z_{1i}]$$

Deberemos buscar z_{1i} , una variable instrumental de x_{3i} , que cumpla las siguientes propiedades:

$$E(z_{1i}, u_i) = E(Z'U) = 0 \quad (\text{condición de exogeneidad})$$

$$E(z_{1i}, x_{3i}) = E(Z'X) \neq 0 \quad (\text{condición de relevancia})$$

Buscamos la variable externa que más correlacione con x_3 y estimamos por variables instrumentales:

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

La nueva estimación sí será **consistente**:

$$\hat{\beta}_{VI} = (Z'X)^{-1}(Z'Y) = (Z'X)^{-1}(Z'(X\beta + U)) = \beta + (Z'X)^{-1}(Z'U)$$

$$p \lim_{N \rightarrow \infty} \hat{\beta}_{VI} = \beta + p \lim_{N \rightarrow \infty} \left[\left(\frac{Z'X}{N} \right)^{-1} \right] p \lim_{N \rightarrow \infty} \left[\left(\frac{Z'U}{N} \right) \right]$$

$$p \lim_{N \rightarrow \infty} \left[\frac{1}{N} (Z'U) \right] = 0 \quad \Rightarrow \quad p \lim_{N \rightarrow \infty} \hat{\beta}_{VI} = \beta$$

Sin embargo, **no será eficiente** ya que no tendrá la mínima varianza. Cuanto mayor sea la correlación entre la variable original y su instrumento, más eficiente será el estimador por VI. Si nos equivocamos en que había endogeneidad y estimamos por VI, tendremos estimaciones ineficientes, peores que con MCO. Debemos tener en cuenta dos cosas:

- 1.- Para comprobar si z_{1i} es un buen instrumento para x_{3i} habría que realizar la siguiente regresión auxiliar:

$$x_{3i} = \gamma_1 + \gamma_2 x_{2i} + \gamma_3 z_{1i} + u_i \quad \text{con } \gamma_3 \text{ significativo}$$

- 2.- El cálculo de la R^2 después de la estimación por VI no tiene sentido y no puede valorarse.

Exemple: $salari_i = \beta_1 + \beta_2 nivell\ educatiu_i + \beta_3 capacitat_i + v_i$

Però *Capacitat* no es pot quantificar, de manera que es treu del model i s'especifica el següent model:

$salari_i = \beta_1 + \beta_2 nivell\ educatiu_i + u_i$ on $u_i = \beta_3 capacitat_i + v_i$

Model 1: OLS, using observations 1-428				
Dependent variable: l_WAGE				
	Coefficient	Std. Error	t-ratio	p-value
const	-0.185197	0.185226	-0.9998	0.31795
EDUC	0.108649	0.0143998	7.5451	<0.00001 ***

On WAGE: Salari \$ per hora
EDUC: Anys d'educació

En aquest cas, com molt probablement la variable inclosa *nivell educatiu* estigui correlacionada amb la variable exclosa *capacitat*, els estimadors per MQO que hem obtingut a l'exemple anterior seran inconsistents ja que :

$E[nivell\ educatiu_i, u_i] \neq 0$



$X = [1\ nivell\ educatiu_i]$ → Variable *nivell educatiu* amb problemes d'endogenitat que caldrà instrumentalitzar

Caldrà definir una variable instrumental z_i , per la variable *nivell educatiu* que estigui altament correlacionada amb aquesta i que estigui incorrelacionada amb el terme de pertorbació....Per exemple, *nivell educatiu del pare*. Per a què aquesta variable sigui un instrument vàlid, caldrà que:

1º) $E[nivell\ educatiu\ pare_i, u_i] = 0$ → Díficil de contrastar ja que u_i no és observable...Però podem suposar que aquesta variable no està relacionada amb la capacitat de l'individu...

2º) $E[nivell\ educatiu_i, nivell\ educatiu\ pare_i] \neq 0$

Aquesta segona condició és fàcilment contrastable...

$nivell\ educatiu_i = \gamma_1 + \gamma_2 nivell\ educatiu\ pare_i + v_i$

Model 2: OLS, using observations 1-428			
Dependent variable: EDUC			
	Coefficient	Std. Error	t-ratio
const	10.23371	0.275936	37.0993
EDUC_FATHER	0.269442	0.0285863	9.4255

Mean dependent var	12.65888	S.D. dependent var	2.285376
Sum squared resid	1845.354	S.E. of regression	2.081302
R-squared	0.172560	Adjusted R-squared	0.170617
F(1, 426)	88.84076	P-value(F)	2.76e-19
Log-likelihood	-920.0246	Akaike criterion	1844.049
Schwarz criterion	1852.167	Hannan-Quinn	1847.255

Donat que la variable *nivell educatiu del pare* ha resultat ser rellevant a la regressió auxiliar efectuada, podem dir que la variable *nivell educatiu del pare* és un instrument vàlid per la variable *nivell educatiu*!!!

Este dossier está hecho para seguir la clase de prueba.

Si te apuntas al curso te enviaremos por correo el dossier entero con todos los temas que faltan, ejercicios y exámenes de años anteriores

Más información en:

www.estadistix.com

**Y si tienes cualquier consulta,
escribenos un whatsapp al 644310902**

