

εσταδιστιχ̄


εσταδιστιχ̄

Econometría I

Grado en Economía UAM

ΕΣΤΑΔΙΣΤΙΧ

Apuntes



1. NATURALEZA DE LA ECONOMETRÍA Y DE LOS DATOS ECONÓMICOS

RECORDATORIO DEL MODELO DE REGRESIÓN



¿QUÉ ES LA ECONOMETRÍA?

La **Econometría** es la rama de la Economía que se ocupa del análisis cuantitativo de los fenómenos económicos reales, siguiendo un enfoque probabilístico. Trata de encontrar, cuantificar y contrastar relaciones económicas entre variables utilizando la modelización matemática y las técnicas basadas en los métodos inferenciales de la estadística. El Econometría se nutre de tres disciplinas: Teoría Económica, Matemáticas y Estadística.

Diferencias modelo económico y econométrico

El **modelo econométrico** exige una especificación estadística más precisa de las variables que lo componen y exige una forma funcional definida, mientras que el económico es más teórico.

Los modelos econométricos se establecen, comúnmente, como relaciones aleatorias o no deterministas (estocásticas) entre variables, suponiéndose la existencia de elementos de azar, frente a las relaciones exactas o fijas que proponen los modelos económicos (determinista).

Modelo económico: $Consumo = f(Renta)$

Model econométrico: $Consumo_i = \beta_0 + \beta_1 Renta_i + u_i$

CASUALIDAD Y NOCIÓN CETERIS PARIBUS

Si encontramos una relación entre dos variables no implica que una sea causa de la otra, significan que varían conjuntamente, que correlacionan. Para valorar la **causalidad** se debería hacer un experimento y recoger **datos experimentales** y no observacionales, modificando la VI y observando si se producen cambios en la VD, y controlando todas las demás variables de confusión. Únicamente se puede establecer causalidad bajo el supuesto **Ceteris Paribus** (manteniendo todos los demás factores constantes).

Ejemplo:

ETAPAS DEL ANÁLISIS ECONÓMICO EMPÍRICO

- Especificación:
- Estimación:
- Validación:
- Utilización o predicción:

ESTRUCTURA DE LOS DATOS ECONÓMICOS

Corte transversal o sección cruzada (x_i): Las observaciones corresponden a diferentes unidades económicas (individuos, empresas países ...) por un único período de tiempo.

Series temporales o longitudinales (x_t): Las observaciones corresponden a diferentes periodos de tiempo (años, meses, días ...) por un única unidad económica.

Datos de panel (x_{it}): Las observaciones corresponden a diferentes unidades económicas y para cada una de las diferentes unidades tenemos información para varios períodos de tiempo.

2. EL MODELO CLÁSICO DE REGRESIÓN

PRESENTACIÓN DEL MODELO

Notación algebraica $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + u_i$

Notación matricial $Y = X\beta + u$

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} (nx1) \quad X = \begin{bmatrix} 1 & x_{11} & \dots & x_{k1} \\ 1 & x_{12} & & x_{k2} \\ \vdots & \vdots & & \vdots \\ 1 & x_{1n} & & x_{kn} \end{bmatrix} (nxK) \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} (Kx1) \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} (nx1)$$

Variable Y: endógena, explicada, dependiente, respuesta, regresando o causada.

Variables X: exógenas, explicativas, independientes, de control, regresoras o causantes.

Coefficientes: es la medida del efecto de x en y. En el modelo poblacional son fijos y desconocidos y el objetivo será estimarlos a partir de los datos de una muestra.

Variable u, residual, error o perturbación: $u_i = y_i - \hat{y}_i$

Ejemplo Eviews:

Dependent Variable: SALARIOM				
Method: Least Squares				
Sample (adjusted): 1 300				
Included observations: 300				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	767.2631	180.4930	4.250929	0.0000
EDUC	72.84627	14.05438	5.183172	0.0000
EXPER	20.06167	2.207412	9.088321	0.0000
MALE	93.45670	13.54719	6.898605	0.0000
R-squared	0.951607	Mean dependent var		17702.50
Adjusted R-squared	0.949015	S.D. dependent var		1153.264
S.E. of regression	113.2656	F-statistic		367.0678
Sum squared resid	3797413.	Prob(F-statistic)		0.000000

Modelo simple: $y_i = \beta_0 + \beta_1 x_{1i} + u_i$

Modelo múltiple: $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + u_i$

HIPÓTESIS DEL MODELO**H1: Linealidad****H2: Exogeneidad estricta**

No debe haber relación lineal entre la perturbación aleatoria y las exógenas. $E(u/x) = 0$

H3: Ausencia de multicolinealidad

No es posible expresar una columna de la matriz X como una combinación lineal del resto de columnas.
Debe haber siempre más observaciones que parámetros.

H4: Perturbaciones esféricas

La perturbación aleatoria debe mantener su varianza constante (**homocedasticidad**) y que no mantenga ningún tipo de tendencia (**no autocorrelación**)

- Homocedasticidad $E(u_i^2/X) = \sigma^2$

- No autocorrelación $E(u_i u_j/X) = 0$

$$\text{Esfericidad} \rightarrow E(uu'/X) = \sigma^2 \cdot I = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix}$$

Expresión matricial de los supuestos:

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

X no aleatoria: X es una matriz determinística.

Esperanza nula: $E(u) = 0_{n \times 1}$

Homocedasticidad y no correlación serial: $V(u) = \sigma^2 I_n$.

No multicolinealidad: $\rho(X) = K$.

ESTIMACIÓN MCO

Modelo poblacional $y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u_i$

Modelo muestral $y_i = \widehat{\beta}_0 + \widehat{\beta}_1 x_1 + \widehat{\beta}_2 x_2 + \dots + \widehat{\beta}_k x_k + \widehat{u}_i$

Un buen estimador es insesgado, eficiente y consistente/robusto.

Mínimos Cuadrados Ordinarios (MCO): los coeficientes que minimizan la suma de los residuos al cuadrado.

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} (nx1) \quad X = \begin{bmatrix} 1 & x_{11} & \dots & x_{k1} \\ 1 & x_{12} & & x_{k2} \\ \vdots & \vdots & & \vdots \\ 1 & x_{1n} & & x_{kn} \end{bmatrix} (nxK) \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} (Kx1) \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} (nx1)$$

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

PROPIEDADES ALGEBRÁICAS DE LOS ESTIMADORES

P1.- $X' \hat{u} = 0$ Regresores y residuos son ortogonales

P2.- $\hat{y}' \hat{u} = 0$ siendo $\hat{y} = X \hat{\beta}_{MCO}$

P3.- $y' y = \hat{y}' \hat{y} + \hat{u}' \hat{u}$

P4.- $\hat{u}' \hat{u} = y' y - \hat{y}' \hat{y} = y' y - \hat{\beta}' X' X \hat{\beta} = y' y - \hat{\beta}' X' y$

P5.- Si el modelo tiene término constante:

$$\sum_{i=1}^n \hat{u}_i = 0$$

Demostraciones.....

$$\sum_{i=1}^n y_i = \sum_{i=1}^n \hat{y}_i$$

PROPIEDADES ESTADÍSTICAS DE LOS ESTIMADORES

Linealidad: Los estimadores MCO son una combinación lineal de las perturbaciones aleatorias

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

Insesgadez: la esperanza del estimador es su parámetro $E(\hat{\beta}_i) = \beta_i$

$$E(\hat{\beta}) = E(\beta + (X'X)^{-1}X'U) = \beta + (X'X)^{-1}X' \cdot E(U) = \beta + (X'X)^{-1}X' \cdot 0 = \beta$$


Optimalidad o eficiencia: la varianza del estimador es la mínima posible: $var(\hat{\beta}_{MCO}) < var(\hat{\beta}_i)$. También se puede definir como que la varianza del estimador coincida con la cota Cramer-Raó (la mínima posible)

$$Var(\hat{\beta}) = \sigma^2(X'X)^{-1} = \begin{pmatrix} Var(\hat{\beta}_1) & Cov(\hat{\beta}_2\hat{\beta}_1) & \dots & Cov(\hat{\beta}_k\hat{\beta}_1) \\ Cov(\hat{\beta}_1\hat{\beta}_2) & Var(\hat{\beta}_2) & \dots & \dots \\ \dots & \dots & \dots & \dots \\ Cov(\hat{\beta}_1\hat{\beta}_k) & \dots & \dots & Var(\hat{\beta}_k) \end{pmatrix}$$

Teorema de Gauss-Markov: "Bajo los supuestos clásicos, los estimadores MCO son Estimadores Lineales, Insesgados y Óptimos (ELIO)"

Además de las propiedades anteriores, el estimador MCO es **consistente**, es decir, que cuando contamos con todos los datos y no con una muestra, el cálculo de MCO da como resultado los parámetros reales.

$$p \lim_{n \rightarrow \infty} (\hat{\beta}_i) = \beta_i \quad p \lim_{n \rightarrow \infty} (var \hat{\beta}_i) = 0$$



BONDAD DE AJUSTE

Siempre que el modelo tenga término independiente se puede afirmar que: $STC = SEC + SRC$

STC: Suma de cuadrados totales $\rightarrow \sum (y_i - \bar{y})^2$

SEC: Suma de cuadrados explicado por el modelo $\rightarrow \sum (\hat{y}_i - \bar{y})^2$

SRC: Suma de cuadrados no explicado o de residuos cuadrados $\rightarrow \sum (y_i - \hat{y}_i)^2 = \sum \hat{u}_i^2$

El **coeficiente de determinación R^2** :

$$R^2 = \frac{SEC}{STC} = 1 - \frac{SRC}{STC} = R^2 = r_{xy}^2 (\text{modelo simple})$$

El **coeficiente de determinación R^2 ajustado o corregido**:

$$\bar{R}^2 = 1 - \left[\frac{n-1}{n-K} \cdot (1 - R^2) \right] \quad \bar{R}^2 \leq R^2$$

ERROR ESTÁNDAR DE LA REGRESIÓN

$$\hat{u}_i = e_i = y_i - \hat{y}_i \quad \hat{\sigma}^2 = \text{Var}(\hat{u}_i) = \frac{SRC}{n-K} = \frac{\sum \hat{u}_i^2}{n-K} = \frac{\hat{u}'\hat{u}}{n-K} \quad \hat{\sigma} = \sqrt{\hat{\sigma}^2}$$

$$\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1} = \begin{pmatrix} \text{Var}(\hat{\beta}_1) & \text{Cov}(\hat{\beta}_2\hat{\beta}_1) & \dots & \text{Cov}(\hat{\beta}_k\hat{\beta}_1) \\ \text{Cov}(\hat{\beta}_1\hat{\beta}_2) & \text{Var}(\hat{\beta}_2) & \dots & \dots \\ \dots & \dots & \dots & \dots \\ \text{Cov}(\hat{\beta}_1\hat{\beta}_k) & \dots & \dots & \text{Var}(\hat{\beta}_k) \end{pmatrix}$$

Ejemplo Eviews:

Dependent Variable: SALARIOM				
Method: Least Squares				
Sample (adjusted): 1 300				
Included observations: 300				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	767.2631	180.4930	4.250929	0.0000
EDUC	72.84627	14.05438	5.183172	0.0000
EXPER	20.06167	2.207412	9.088321	0.0000
MALE	93.45670	13.54719	6.898605	0.0000
R-squared	0.951607	Mean dependent var		17702.50
Adjusted R-squared	0.949015	S.D. dependent var		1153.264
S.E. of regression	113.2656	F-statistic		367.0678
Sum squared resid	3797413.	Prob(F-statistic)		0.000000

FUNCIONES DE REGRESIÓN NO LINEALES

En muchas ocasiones nos encontramos en Economía con relaciones no lineales. En este caso muchas veces podemos transformar el modelo con logaritmos y conseguir un modelo lineal:

$$y_i = L_i^{\beta_0} * K_i^{\beta_1} * u_i \rightarrow \ln(y_i) = \beta_0 \ln(L_i) + \beta_1 \ln(K_i) + \ln(u_i)$$

Pero la interpretación de los coeficientes cambia:

1. $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ el coef. $\hat{\beta}_1$ nos indica el cambio medio esperado en y por cada unidad de x .
2. $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 \ln(x_i)$ el coef. $\hat{\beta}_1$ nos indica que si $x \uparrow 1\%$, esperamos que y aumente en $\frac{\hat{\beta}_1}{100}$ unidades
3. $\widehat{\ln(y_i)} = \hat{\beta}_0 + \hat{\beta}_1 x_i$ el coef. $\hat{\beta}_1$ nos indica que si $x \uparrow 1u$, esperamos que y aumente en $100 \cdot \hat{\beta}_1 \%$
4. $\widehat{\ln(y_i)} = \hat{\beta}_0 + \hat{\beta}_1 \ln(x_i)$ el coef. $\hat{\beta}_1$ nos indica que si $x \uparrow 1\%$, esperamos que y aumente en $\hat{\beta}_1 \%$

Ejemplos:

MODELO CUADRÁTICO

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + u_i$$

El efecto marginal es la derivada respecto a la x : $\beta_1 + 2\beta_2 x_1$

Ejemplo:

EXÓGENAS CATEGÓRICAS

Si queremos incluir una variable categórica dicotómica en el modelo lo podemos hacer, siempre que la convirtamos en una variable "dummy" o ficticia, donde los dos valores sea 0 y 1. De esa manera, el coeficiente significará el aumento esperado de y por ser de la categoría 1 respecto a la 0.

Ejemplos:

Ejemplo Eviews:

Dependent Variable: L_NOTA_FINAL				
Method: Least Squares				
Sample (adjusted): 1 22				
Included observations: 22				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.564198	0.563828	1.0010	0.3310
NOTA_PARCIAL	0.115344	0.371480	3.1050	0.0064
L_ASISTENCIA	-0.891568	0.866862	-1.0280	0.3181
EDAD	0.013787	0.019807	0.6961	0.4958
ACADEMIA	0.356599	0.144600	2.4660	0.0246
R-squared	0.658501	Mean dependent var		1.824567
Adjusted R-squared	0.578149	S.D. dependent var		0.420078
S.E. of regression	0.272841	F-statistic		8.195145
Sum squared resid	1.265520	Prob(F-statistic)		0.000713

MODELO DE DESVIACIONES RESPECTO A LA MEDIA

$$y_i - \bar{y} = \widehat{\beta}_0 + \widehat{\beta}_1(x_{1i} - \bar{x}_1) + \widehat{\beta}_2(x_{2i} - \bar{x}_2) + \dots + \widehat{\beta}_k(x_{ki} - \bar{x}_k) + \widehat{u}_i$$

$$Q = I_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^t \quad \text{simétrica e idempotente}$$

$$\tilde{Y} \equiv QY = \begin{pmatrix} y_1 - \bar{y} \\ y_2 - \bar{y} \\ \vdots \\ y_n - \bar{y} \end{pmatrix}$$

$$\tilde{X} \equiv QX = \begin{pmatrix} 0 & x_{11} - \bar{x}_1 & \dots & x_{1k} - \bar{x}_k \\ 0 & x_{21} - \bar{x}_1 & \dots & x_{2k} - \bar{x}_k \\ \vdots & \vdots & \ddots & \vdots \\ 0 & x_{n1} - \bar{x}_1 & \dots & x_{nk} - \bar{x}_k \end{pmatrix} = [0; \tilde{X}_1]$$

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,
escríbenos un whatsapp al 644310902**

