

Introduccion a los Modelos de Regresion

Walter Sosa Escudero

(wsosa@udesa.edu.ar)

Universidad de San Andres

- Hayashi (2000) Capitulo 1, pp. 3-46.
- Cualquier texto basico de econometria (con matrices!!!)

Modelo lineal:

$$y_i = \beta_1 + \beta_2 x_{2i} + \cdots + \beta_K x_{Ki} + u_i, \quad i = 1, \dots, N$$

$$Y = X\beta + u$$

Y , vector de n de observaciones

X , matriz $n \times K$, primera columna con unos.

u , vector de n términos de error.

- Cuántas variables explicativas hay en este modelo?
- El objetivo es estimar β .
- En los cursos básicos X es tratada como fija. Es extraño en una disciplina no experimental.

$$E(Y|X = x) = \int y f_{Y|X} dy$$

Idea: como cambia la esperanza de Y cuando X cambia. Es una *funcion* que depende de X . Si X es una variable aleatoria, $E(Y|X)$ es una variable aleatoria.

Propiedades:

- $E(X|X) = X$
- $Y = a + bX + U$, entonces $E(Y|X) = a + bX + E(U|X)$.
- *Ley de esperanzas iteradas:* $E(Y) = E[E(Y|X)]$.

- **Exogeneidad estricta:** $E(u_i|X) = 0$, $i = 1, 2, \dots, n$.

Implica dos cosas:

- $E(u_i) = 0$. Por LIT, $E(u_i) = E(E(u|X)) = E(0) = 0$.
 - $E(x_{jk}u_i) = 0$ (idem anterior, v/como ejercicio).
- **No multicolinealidad:** $\rho(X) = K$.
 - **Varianza esferica**
 - *Homocedasticidad:* $V(u_i|X) = E(u_i^2|X) = \sigma^2$, $\forall i$.
 - *No correlacion serial:*
 $Cov(u_i, u_j|X) = E(u_i u_j|X) = 0$, $i \neq j$.

En terminos matriciales: $V(u|X) = E(uu'|X) = \sigma^2 I$.

Definamos:

$$\hat{Y} \equiv X\hat{\beta}, \quad e \equiv Y - \hat{Y} = Y - X\hat{\beta}$$

Estimador minimo-cuadratico:

$$\hat{\beta} = \operatorname{argmin}_b \sum_{i=1}^n e_i^2 = \operatorname{argmin}_b \sum_{i=1}^n e'e$$

Solucion:

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

Estimation of σ^2 : usamos $S^2 = e'e/(n - K)$.

$$E(y_i|x_i) = \beta_1 + \beta_2 x_{2i} + \cdots + \beta_{K_i} x_{K_i}$$

- Si las variables x_{ik} son funcionalmente independientes:

$$\beta_k = \frac{\partial E(y_i|x_i)}{\partial x_k}$$

- Si x_{ki} es una variable binaria (1 si i pertenece a una clase, 0 si no)

$$\beta_k = E(y|x_k = 1) - E(y|x_k = 0)$$

- Dos modelos 'no lineales':

- Cuadrático:

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + u_i$$

- Interactivo:

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i z_i + u_i$$

Como se interpretan los coeficientes en estos casos?

Descomposicion de suma de cuadrados y R^2

Si el modeo tiene una constante:

$$\sum_{\text{SCT}} (Y_i - \bar{Y})^2 = \sum_{\text{SCE}} (\hat{Y}_i - \bar{Y})^2 + \sum_{\text{SCR}} e_i^2$$

Medida de bondad del ajuste:

$$R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT}$$

1. **Linealidad:** $\hat{\beta}$ es *lineal*: $\exists A_{K \times N}$ tal que $\hat{\beta} = AY$.

Prueba: Tomar $A = (X'X)^{-1}X'$.

2. **Insesgadez:** $E(\hat{\beta}) = \beta$.

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1}X'Y \\ &= (X'X)^{-1}X'(X\beta + u) \\ &= \beta + (X'X)^{-1}X'u \\ E(\hat{\beta}) &= \beta + E[(X'X)^{-1}X'u] \\ &= \beta + E[(X'X)^{-1}X'E(u|X)] \\ &\quad \text{(Ley de esperanzas iteradas)} \\ &= \beta \quad \text{(Dado que } E(u|X) = 0\text{)}\end{aligned}$$

3. **Varianza:** $V(\hat{\beta}) = \sigma^2(X'X)^{-1}$.

$$\begin{aligned} V(\hat{\beta}) &= E[(\beta - E(\hat{\beta}))(\beta - E(\hat{\beta}))'] \\ &= E[(\beta - \beta)(\beta - \beta)'] \quad (\text{porque?}) \\ &= E[(X'X)^{-1}X'uu'X(X'X)^{-1}] \quad (\text{prueba anterior...}) \\ &= \quad (\text{a partir de aca los deajo solos...}) \end{aligned}$$

4. **Teorema de Gauss-Markov:** Bajo todos los supuestos clasicos, para cualquier estimador lineal e insesgado $\tilde{\beta}$,

$$V(\tilde{\beta}) - V(\hat{\beta}) \geq 0$$

Generalmente se dice que el estimador MCO es el mejor lineal insesgado.

Prueba (X no aleatoria):

Que $\tilde{\beta}$ sea lineal implica que existe una matriz no estocastica $A_{K \times n}$ de rango K , tal que $\tilde{\beta} = AY$. Bajo los supuestos clasicos

$$E(\tilde{\beta}) = A E(Y) = A(X\beta + E(u)) = AX\beta \quad (1)$$

Que $\tilde{\beta}$ sea insesgado implica que

$$E(\tilde{\beta}) = \beta \quad (2)$$

Consecuentemente, que $\tilde{\beta}$ sea lineal e insesgado implica que (1) y (2) tienen que cumplirse simultaneamente, lo cual ocurre si y solo si $AX = I$.

Trivialmente:

$$\tilde{\beta} = \hat{\beta} + \tilde{\beta} - \hat{\beta} \equiv \hat{\beta} + \hat{\gamma} \quad (3)$$

con $\hat{\gamma} \equiv \tilde{\beta} - \hat{\beta}$. Notar que:

$$V(\tilde{\beta}) = V(\hat{\beta}) + V(\hat{\gamma}) \quad (4)$$

si $Cov(\hat{\beta}, \hat{\gamma}) = 0$). Esto es lo que probaremos. Notar que

$$\begin{aligned} \hat{\gamma} &= AY - (X'X)^{-1}X'Y \\ &= (A - (X'X)^{-1}X')Y \\ &= (A - (X'X)^{-1}X')(X\beta + u) \\ &= (A - (X'X)^{-1}X')u \quad (\text{prueba anterior...}) \end{aligned}$$

ya que $AX = X'A' = I$ por el resultado anterior, de lo que obtenemos

$$E(\hat{\gamma}) = 0$$

Adicionalmente:

$$\begin{aligned} \text{Cov}(\hat{\beta}, \hat{\gamma}) &= E[(\hat{\beta} - \beta)\hat{\gamma}'] \\ &= E[(X'X)^{-1}X'u u'(A - (X'X)^{-1}X')] \\ &= \sigma^2[(X'X)^{-1}X'(A' - X(X'X)^{-1})] \\ &= \sigma^2[(X'X)^{-1}X'A' - (X'X)^{-1}X'X(X'X)^{-1}] \\ &= 0 \end{aligned}$$

donde hemos utilizado que $V(u) = E(uu') = \sigma^2$, y, nuevamente, que $AX = I$.

Entonces, despejando en (4):

$$V(\tilde{\beta}) - V(\hat{\beta}) = V(\hat{\gamma})$$

que por definicion es semidefinida positiva, lo cual concluye la prueba. ■

5. (Insesgadez de S^2): $E(S^2) = \sigma^2$.

Sugiere que podemos estimar $V(\hat{\beta}) = \sigma^2(X'X)^{-1}$ usando:

$$\hat{V}(\hat{\beta}) = S^2(X'X)^{-1}$$

Supuesto adicional: (**Normalidad**) $u|X \sim N(0, \sigma^2 I)$

- **Hipotesis individuales:** $H_0 : \beta_k = \beta_{k0}$ vs. $H_A : \beta_k \neq \beta_{k0}$.
Resultado: bajo H_0 :

$$z_k \equiv \frac{\hat{\beta}_k - \beta_{k0}}{\sqrt{\hat{V}(\hat{\beta}_k)}} \sim t_{n-K}.$$

- **Significatividad global:** $H_0 : \beta_2 = 0, \beta_3 = 0, \dots, \beta_K = 0$
vs. $H_A : \beta_2 \neq 0 \vee \beta_3 \neq 0 \vee \dots, \vee \beta_K \neq 0$.
Resultado: bajo H_0 :

$$F = \frac{ESS/(K-1)}{RSS/(n-K)} \sim F(K-1, n-K)$$