

Taller #2 Econometría 06169

Profesor: Julio César Alonso

Nota: Recuerden que únicamente dos preguntas seleccionadas al azar serán calificadas

1) Demuestre que $s^2 = \frac{\hat{\varepsilon}^T \hat{\varepsilon}}{n-k}$ es equivalente a $s^2 = \frac{y^T y - \hat{\beta}^T X^T y}{n-k}$
y además demuestre que s^2 es un estimador insesgado de σ^2 .

2.)

Se tiene la siguiente información para el modelo $y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \varepsilon_i$:

$$X^T \cdot y = \begin{pmatrix} 120 \\ 30 \\ 43 \end{pmatrix} \quad X^T X = \begin{pmatrix} 100 & 20 & 0 \\ 20 & 10 & 0 \\ 0 & 0 & 10 \end{pmatrix} \quad y^T y = 510$$

a) Encuentre $(X^T X)^{-1}$.

b) Estime por MCO el siguiente modelo $y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \varepsilon_i$ usando las siguientes observaciones recogidas por un investigador. Es decir encuentre los estimadores para β_1 , β_2 , β_3 y σ^2 .

c) Contraste la hipótesis nula $H_0: \beta_3 = 0$. Explique las implicaciones de su decisión

d) Construya un intervalo de confianza del 95% para β_2 .

3. ¿Cuáles de las siguientes relaciones funcionales se pueden estimar por medio de un modelo lineal? (Explique su respuesta. Muestre todo su trabajo)

$$\begin{array}{ll} \text{a) } y_i = \left[\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \right] + \frac{1}{\varepsilon_i} & \text{b) } U_t = \alpha \left(\frac{w_t \cdot \varepsilon_t}{p_t} \right)^\beta \\ \text{c) } y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta}} + \frac{1}{\varepsilon_i} & \\ \text{d) } y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \cdot \varepsilon_i} & \text{e) } U_t = \left[\alpha + \left(\frac{w_t \cdot \varepsilon_t}{p_t} \right)^\beta \right]^\frac{1}{\beta} \end{array}$$

Donde ε_i y ε_t representan términos de error aleatorio.

4. Dado el modelo $\ln(Y_i) = \beta_1 + \beta_2 \cdot \ln(X_{2i}) + \beta_3 \cdot \ln(X_{3i}) + \varepsilon_i$, pruebe que los coeficientes de regresión estimados corresponden a las elasticidades asociadas con cada X y que esas elasticidades son constantes a lo largo de la línea de regresión.

Taller #2
Econometría 06169
Respuestas Sugerida

Profesor: Julio César Alonso

Nota: Recuerden que únicamente dos preguntas seleccionadas al azar serán calificadas

1) Demuestre que $s^2 = \frac{\hat{\varepsilon}^T \hat{\varepsilon}}{n-k}$ es equivalente a $s^2 = \frac{y^T y - \hat{\beta}^T X^T y}{n-k}$

y además demuestre que s^2 es un estimador insesgado de σ^2 .

NOTA: Esta pregunta no era facil, requería un poco de investigación.

Remplazando en la expresión original y aplicando algebra matricial, tenemos:

$$s^2 = \frac{\hat{\varepsilon}^T \hat{\varepsilon}}{n-k} = \frac{(y - \hat{y})^T (y - \hat{y})}{n-k} = \frac{(y^T - \hat{y}^T)(y - \hat{y})}{n-k} = \frac{(y^T - (X\hat{\beta})^T)(y - (X\hat{\beta}))}{n-k}$$

$$s^2 = \frac{(y^T - (\hat{\beta}^T X^T))(y - (X\hat{\beta}))}{n-k} = \frac{y^T y - (\hat{\beta}^T X^T)y - y^T (X\hat{\beta}) + (\hat{\beta}^T X^T)(X\hat{\beta})}{n-k}$$

Nosotros sabemos que $\hat{\beta} = (X^T X)^{-1} X^T y$ entonces tenemos que

$$s^2 = \frac{y^T y - (\hat{\beta}^T X^T)y - y^T (X\hat{\beta}) + \left(\left((X^T X)^{-1} X^T y \right)^T X^T \right) (X\hat{\beta})}{n-k}$$

$$s^2 = \frac{y^T y - (\hat{\beta}^T X^T)y - y^T (X\hat{\beta}) + \left(y^T X (X^T X)^{-1} X^T \right) (X\hat{\beta})}{n-k}$$

$$s^2 = \frac{y^T y - (\hat{\beta}^T X^T)y - y^T (X\hat{\beta}) + \left(y^T X (X^T X)^{-1} X^T X \hat{\beta} \right)}{n-k}$$

$$s^2 = \frac{y^T y - (\hat{\beta}^T X^T)y - y^T (X\hat{\beta}) + (y^T X \hat{\beta})}{n-k} = \frac{y^T y - \hat{\beta}^T X^T y}{n-k}$$

Q.E.D.

Ahora necesitamos demostrar que: $E[s^2] = \sigma^2$

Como vimos anteriormente, sabemos que:

$$E[s^2] = E\left[\frac{\hat{\varepsilon}^T \hat{\varepsilon}}{n-k}\right] = \frac{1}{n-k} E[\hat{\varepsilon}^T \hat{\varepsilon}]$$

Antes de seguir, noten que:

$$\hat{\varepsilon} = y - X\hat{\beta} = y - X(X^T X)^{-1} X^T y = [I - X(X^T X)^{-1} X^T] y$$

Ahora definamos,

$$M_X = [I - X(X^T X)^{-1} X^T]$$

Entonces,

$$\hat{\varepsilon} = M_X y$$

Además, es fácil mostrar que M_X es idempotente, pues

$$M_X \cdot M_X = [I - X(X^T X)^{-1} X^T][I - X(X^T X)^{-1} X^T]$$

$$M_X \cdot M_X = I - X(X^T X)^{-1} X^T - X(X^T X)^{-1} X^T + X(X^T X)^{-1} X^T X(X^T X)^{-1} X^T$$

$$M_X \cdot M_X = I - X(X^T X)^{-1} X^T - X(X^T X)^{-1} X^T + X(X^T X)^{-1} X^T$$

$$M_X \cdot M_X = I - X(X^T X)^{-1} X^T = M_X$$

Ahora sí, veamos a que es igual $E[\hat{\varepsilon}^T \hat{\varepsilon}]$

$$E[\hat{\varepsilon}^T \hat{\varepsilon}] = E[\varepsilon^T M_X M_X \varepsilon] = E[\varepsilon^T M_X \varepsilon]$$

Ahora, como este producto es igual a un escalar, será lo mismo el valor esperado de la traza o simplemente el valor esperado (¿por qué?). Empleando las propiedades del valor esperado y de la traza, tenemos que:

$$E[\hat{\varepsilon}^T \hat{\varepsilon}] = \text{tra}[E[\hat{\varepsilon}^T \hat{\varepsilon}]] = E[\text{tra}[\varepsilon^T M_X \varepsilon]] = E[\text{tra}[M_X \varepsilon^T \varepsilon]]$$

$$E[\hat{\varepsilon}^T \hat{\varepsilon}] = \text{tra}[M_X E[\varepsilon^T \varepsilon]] = \text{tra}[M_X \sigma^2 I_n] = \sigma^2 \text{tra}[M_X]$$

Noten que

$$\text{tra}[M_X] = \text{tra}\left[I - X(X^T X)^{-1} X^T\right] = \text{tra}[I_n] - \text{tra}\left[X(X^T X)^{-1} X^T\right]$$

Así,

$$\text{tra}[M_X] = n - \text{tra}\left[(X^T X)^{-1} X^T X\right] = n - \text{tra}[I_k] = n - k$$

$$E\left[\hat{\varepsilon}^T \hat{\varepsilon}\right] = (n - k) \sigma^2$$

Por tanto:

$$E\left[s^2\right] = E\left[\frac{\hat{\varepsilon}^T \hat{\varepsilon}}{n - k}\right] = \frac{1}{n - k} E\left[\hat{\varepsilon}^T \hat{\varepsilon}\right] = \frac{(n - k) \sigma^2}{n - k} = \sigma^2$$

Q.E.D.

2.)

Se tiene la siguiente información para el modelo $y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \varepsilon_i$:

$$X^T \cdot y = \begin{pmatrix} 120 \\ 30 \\ 43 \end{pmatrix} \quad X^T X = \begin{pmatrix} 100 & 20 & 0 \\ 20 & 10 & 0 \\ 0 & 0 & 10 \end{pmatrix} \quad y^T y = 510$$

a) Encuentre $(X^T X)^{-1}$.

Sin importar el método que empleen, la respuesta debe ser:

$$(X^T X)^{-1} = \begin{pmatrix} \frac{1}{60} & \frac{-1}{30} & 0 \\ \frac{-1}{30} & \frac{1}{6} & 0 \\ 0 & 0 & \frac{1}{10} \end{pmatrix}$$

b) Estime por MCO el siguiente modelo $y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \varepsilon_i$ usando las siguientes observaciones recogidas por un investigador. Es decir encuentre los estimadores para β_1 , β_2 , β_3 y σ^2 .

En este caso tenemos que

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \hat{\beta}_3 \end{bmatrix} = (X^T X)^{-1} X^T y = \begin{pmatrix} \frac{1}{60} & -\frac{1}{30} & 0 \\ -\frac{1}{30} & \frac{1}{6} & 0 \\ 0 & 0 & \frac{1}{10} \end{pmatrix} \cdot \begin{pmatrix} 120 \\ 30 \\ 43 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ \frac{43}{10} \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 4.3 \end{pmatrix}$$

Ahora tenemos que encontrar el estimador para σ^2 .

$$s^2 = \frac{y^T y - \hat{\beta}^T X^T y}{n - k}$$

En este caso tenemos que $k := 3$, $n := 5$ y $y^T y = 510$. Así,

$$s^2 = \frac{510 - \begin{pmatrix} 1 & 1 & \frac{43}{10} \end{pmatrix} \cdot \begin{pmatrix} 120 \\ 30 \\ 43 \end{pmatrix}}{100 - 3} = \frac{510 - \frac{3349}{10}}{97} = \frac{1751}{970} = 1.805$$

Además tenemos que la matriz de varianzas y covarianzas esta dada por

$$\widehat{Var}(\hat{\beta}) = s^2 (X^T X)^{-1} = \frac{1751}{970} \cdot \begin{pmatrix} \frac{1}{60} & -\frac{1}{30} & 0 \\ -\frac{1}{30} & \frac{1}{6} & 0 \\ 0 & 0 & \frac{1}{10} \end{pmatrix} = \begin{pmatrix} \frac{1751}{58200} & -\frac{1751}{29100} & 0 \\ -\frac{1751}{29100} & \frac{1751}{5820} & 0 \\ 0 & 0 & \frac{1751}{9700} \end{pmatrix} = \begin{pmatrix} 0.03 & -0.06 & 0 \\ -0.06 & 0.301 & 0 \\ 0 & 0 & 0.181 \end{pmatrix}$$

c) Contraste la hipótesis nula $H_0: \beta_3 = 0$. Explique las implicaciones de su decisión

Queremos probar la siguiente hipótesis nula $H_0: \beta_3 = 0$, versus la hipótesis alterna $H_A: \beta_3 \neq 0$

. Como vimos en clase el t calculado es dado por la siguiente formula: $t_c = \frac{\hat{\beta}_3}{s(\hat{\beta}_3)}$. En este

caso tenemos

$$t_c = \frac{\frac{43}{10}}{\sqrt{\frac{1751}{9700}}} = 10.121$$

Nota: En el examen yo les daría el valor de esta operación. Es decir les daría $\frac{43}{10} \cdot \frac{1}{\sqrt{\frac{1751}{9700}}}$.

Este t_c lo tenemos que comparar con el $t_{0.025, 97} = 1.661$ de la tabla (Aquí ustedes podían escoger cualquier nivel de significancia y la decisión sería la misma $t_{0.05, 97} = 1.985$ y $t_{0.005, 97} = 2.627$). Note que $|t_c| = 10.121 > t_{0.005, 97}$, por lo tanto hay suficiente evidencia para decir que el coeficiente asociado con el regresor X_3 no es igual a cero. En otras palabras, podemos decir con un 99% de confianza que X_3 ayuda a explicar la variabilidad en la variable dependiente.

d) Construya un intervalo de confianza del 95% para β_2 .

Un intervalo de confianza del 95% para β_2 esta dado por

$$\left(1 - t_{0.025, 97} \cdot \sqrt{\frac{1751}{5820}}, 1 + t_{0.025, 97} \cdot \sqrt{\frac{1751}{5820}} \right)$$

$$\left(1 - 1.661 \cdot \sqrt{\frac{1751}{5820}}, 1 + 1.661 \cdot \sqrt{\frac{1751}{5820}} \right)$$

Nota: Si no tenían calculadora, la línea anterior era suficiente.

$$(0.089, 1.911)$$

3. ¿Cuáles de las siguientes relaciones funcionales se pueden estimar por medio de un modelo lineal? (Explique su respuesta. Muestre todo su trabajo)

a) $y_i = \left[\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \right] + \frac{1}{\varepsilon_i}$ b) $U_t = \alpha \left(\frac{w_t \cdot \varepsilon_t}{p_t} \right)^\beta$ c) $y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} + \varepsilon_i}$

d) $y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \cdot \varepsilon_i}$ e) $U_t = \left[\alpha + \left(\frac{w_t \cdot \varepsilon_t}{p_t} \right) \right]^\beta$

Donde ε_i y ε_t representan términos de error aleatorio.

a) Claramente el modelo $y_i = \left[\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \right] + \frac{1}{\varepsilon_i}$ no es lineal. Este modelo no se puede linearizar, pues no existe una transformación que permita obtener un modelo lineal.

- b) Claramente el modelo $U_t = \alpha \left(\frac{w_t \cdot \varepsilon_t}{p_t} \right)^\beta$ es no lineal, pero se puede linealizar facilmente aplicando logaritmo natural a ambos lados de la ecuación. Es decir,

$$U_t = \alpha \left(\frac{w_t \cdot \varepsilon_t}{p_t} \right)^\beta$$

$$\ln(U_t) = \ln \left[\alpha \cdot (w_t)^\beta \cdot (p_t)^{-\beta} \cdot (\varepsilon_t)^\beta \right]$$

$$\ln(U_t) = \ln(\alpha) + \ln \left[(w_t)^\beta \right] + \ln \left[(p_t)^{-\beta} \right] + \ln \left[(\varepsilon_t)^\beta \right]$$

$$\ln(U_t) = \ln(\alpha) + \beta \cdot \ln(w_t) - \beta \cdot \ln(p_t) + \ln \left[(\varepsilon_t)^\beta \right]$$

Ahora podemos definir los siguientes regresores y coeficientes:

$$y_t = \ln(U_t) \quad X_{1t} = \ln(w_t) - \ln(p_t) \quad \mu_t = \ln \left[(\varepsilon_t)^\beta \right] \quad \eta = \ln(\alpha)$$

Así el modelo original es equivalente a:

$$y_t = \eta + \beta \cdot X_{1t} + \mu_t$$

- c) Claramente el modelo $y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta}} + \frac{1}{\varepsilon_i}$ no es lineal. Este modelo no se puede linearizar, pues no existe una transformación que permita obtener un modelo lineal.

- d) El modelo $y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \cdot \varepsilon_i}$ se puede linealizar de la siguiente forma:

$$y_i = \frac{1}{\alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \cdot \varepsilon_i}$$

$$\frac{1}{y_i} = \alpha \cdot (L_i)^\beta \cdot (K_i)^{1-\beta} \cdot \varepsilon_i$$

$$\ln \left(\frac{1}{y_i} \right) = \ln(\alpha) + \beta \cdot \ln(L_i) + (1 - \beta) \cdot \ln(K_i) + \ln(\varepsilon_i)$$

Ahora podemos definir los siguientes regresores y coeficientes:

$$z_i = \ln \left(\frac{1}{y_i} \right) \quad X_{1i} = \ln(L_i) \quad X_{2i} = \ln(K_i) \quad \mu_i = \ln(\varepsilon_i) \quad \eta = \ln(\alpha)$$

Así el modelo original es equivalente a:

$$y_i = \eta + \beta \cdot X_{1i} + (1 - \beta)X_{2i} + \mu_i$$

e) El modelo $U_t = \left[\alpha + \left(\frac{w_t \cdot \varepsilon_t}{P_t} \right) \right]^{\frac{1}{\beta}}$ no es lineal. Este modelo no se puede linearizar, pues no existe una transformación que permita obtener un modelo lineal.

4. Dado el modelo $\ln(Y_i) = \beta_1 + \beta_2 \cdot \ln(X_{2i}) + \beta_3 \cdot \ln(X_{3i}) + \varepsilon_i$, pruebe que los coeficientes de regresión estimados corresponden a las elasticidades asociadas con cada X y que esas elasticidades son constantes a lo largo de la línea de regresión.

Note que el modelo $\ln(Y_i) = \beta_1 + \beta_2 \cdot \ln(X_{2i}) + \beta_3 \cdot \ln(X_{3i}) + \varepsilon_i$ es equivalente al siguiente modelo

no lineal $Y_i = \beta \cdot (X_{2i})^{\beta_2} \cdot (X_{3i})^{\beta_3} \cdot u_i$, donde $u_i = e^{\varepsilon_i}$ y $\beta = e^{\beta_1}$. Además sabemos que la

elasticidad asociada con X_2 esta dada por: $\eta_{(X_2)} = \frac{\Delta\% \text{en } Y}{\Delta\% \text{en } X_2} = \left(\frac{d}{dX_{2i}} Y_i \right) \cdot \frac{X_{2i}}{Y_i}$. En este caso

$$\frac{d}{dX_{2i}} Y_i = \beta_2 \cdot \beta_1 \cdot (X_{2i})^{\beta_2 - 1} \cdot (X_{3i})^{\beta_3} \cdot u_i = \beta_2 \cdot \frac{\beta_1 \cdot (X_{2i})^{\beta_2} \cdot (X_{3i})^{\beta_3} \cdot u_i}{X_{2i}} = \beta_2 \cdot \frac{Y_i}{X_{2i}}$$

Entonces, tenemos que

$$\eta_{(X_2)} = \frac{\Delta\% \text{en } Y}{\Delta\% \text{en } X_2} = \left(\frac{d}{dX_{2i}} Y_i \right) \cdot \frac{X_{2i}}{Y_i} = \left(\beta_2 \cdot \frac{Y_i}{X_{2i}} \right) \cdot \frac{X_{2i}}{Y_i} = \beta_2$$

De igual forma podemos mostrar que $\eta_{(X_3)} = \beta_3$.