

Tema 2 - Regresión lineal : estimación

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k + \varepsilon$$

función de regresión poblacional (FRP)

$$\mathbb{E}[Y | X_1, \dots, X_k]$$

Y = var. dependiente / endógena

X_i = var. indep. / exógena

$$\bullet \text{ Residuo de la regresión : } \hat{\varepsilon}_i = Y_i - \hat{Y}_i \\ = Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_{1i})$$

$$\bullet \text{ método de los mínimos cuadrados ordinarios (MCO)} \\ = \min_{\beta_0, \beta_1} \sum_{i=1}^n \hat{\varepsilon}_i^2$$

$$\Leftrightarrow \text{Funciones normales} \begin{cases} \sum \hat{\varepsilon}_i = 0 \\ \sum X_{1i} \hat{\varepsilon}_i = 0 \end{cases}$$

$$\Leftrightarrow \hat{\beta}_1 = \frac{\widehat{\text{cov}}(X_1, Y)}{\widehat{\text{var}}(X_1)}, \quad \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}_1$$

$$\bullet \text{ coeficiente de determinación } R^2 = \frac{\text{var}(\hat{Y}_i)}{\text{var}(Y_i)} = 1 - \frac{\text{var}(\hat{\varepsilon}_i)}{\text{var}(Y_i)}$$

$$\text{ya que } Y_i = \hat{Y}_i + \hat{\varepsilon}_i \text{ y } \hat{Y}_i \perp \hat{\varepsilon}_i \dots$$

$$- \text{ Nótese que } R^2 = r^2 = \text{coef. de correlación al cuadrado} = \text{corr}(Y_i, \hat{Y}_i)^2$$

$$\bullet \text{ SCT} = \text{SCE} + \text{SCR}$$

SC = suma cuadrados

$$\Leftrightarrow \sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum \hat{\varepsilon}_i^2$$

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

Regresión múltiple:

$$Y = X\beta + \varepsilon \Rightarrow \hat{\beta}_{\text{MCO}} = (X^T X)^{-1} X^T Y$$

$$\text{Otra vez, } R^2 = \frac{\text{var}(\hat{Y})}{\text{var}(Y)} = \frac{\text{SCE}/n}{\text{SCT}/n} = 1 - \frac{\text{SCR}}{\text{SCT}} = \frac{\sum \hat{\varepsilon}_i^2}{\sum (Y_i - \bar{Y})^2}$$

$$\bullet R^2 \text{ corregido} = 1 - \frac{\text{SCR}/(n-k-1)}{\text{SCT}/(n-1)} = 1 - \frac{\hat{\sigma}^2}{S_y^2}$$

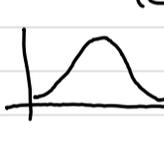
$$\bullet \text{ Modelo de coeficientes beta} \begin{cases} z_y := \frac{Y_i - \bar{Y}}{S_y} \\ z_j := \frac{X_{ij} - \bar{X}_j}{S_{X_j}} \end{cases}$$

Tema 4 - Regresión lineal: Inferencia

- Supuesto 1 :- $y_i = \beta_0 + \dots + \beta_k x_{ki} + \varepsilon_i$
- Matriz $E[x_i x_i^T] > 0$ +ve definida
- Supuesto 2 :- Exogeneidad, i.e.:
 $E[\varepsilon_i | x_i] = 0$.
- Supuesto 3 :- $(x_{1i}, \dots, x_{ki}, y_i)$ son iid.
- Bajo estos supuestos tenemos:
 - ① Insesgadez: $E[\hat{\beta}_j] = \beta_j$ y $E[\hat{\beta}_j | X] = \beta_j$.
 - Si asumimos que $E[x_{ij}^4] < \infty$, $E[y_i^4] < \infty$ entonces
 $\hat{\beta}_1 \xrightarrow{d} N(\beta_1, \sigma^2_{\hat{\beta}_1})$ donde $\sigma^2_{\hat{\beta}_1} = \frac{1}{n} \frac{\text{var}((x_{1i} - \bar{x})x_i)}{\text{var}(x_{1i})^2}$.
 - ↳ Simplemente una aplicación del CLT.
- Def error estándar = $ee(\hat{\beta})$ es un estimador de la desviación típica de la distribución muestral de $\hat{\beta}$.
eg. $ee(\hat{\beta}_1) = \sqrt{\hat{\sigma}^2_{\hat{\beta}_1}} = \sqrt{\widehat{\text{var}}(\hat{\beta}_1)}$
- Supuesto 4: Homocedasticidad $\text{var}(\varepsilon_i | x) = \sigma^2 \forall i$.
↳ Si incluimos este supuesto entonces
 $\text{var}(\hat{\beta} | x) = \sigma^2 (X^T X)^{-1}$
 $\Leftrightarrow \text{var}(\hat{\beta}_j) = \frac{\sigma^2}{SCT_j (1 - R_j^2)}$
donde - $SCT_j = \sum_{t=1}^n (x_{jt} - \bar{x}_j)^2$
- $R_j = \text{coef. de regresión de } x_j \text{ en todas las } x_{i \neq j}$.
- △ Nótase que si hay multicolinealidad perfecta, i.e. $R_j = 1$, el estimador MCO no se puede estimar.
- ↳ Bajo este supuesto $\hat{\sigma}^2 = \frac{\sum_{i=1}^n \hat{\varepsilon}_i^2}{n - k - 1}$ es un estimador insesgado.
- ↳ Teorema Gauss-Markov: bajo este supuesto, los MCO son ELD (insesgados y óptimos).

- Normalidad: si $\varepsilon \sim N(0, \sigma^2)$ entonces $\hat{\beta}_j \sim N(\beta_j, \text{var}(\hat{\beta}_j))$.
 ↓
 Test: estadístico Jarque-Bera $JB = n \left[\frac{S^2}{6} + \frac{(k-3)^2}{24} \right] \sim \chi^2_2$ bajo $H_0: \varepsilon \sim N$
 (weft. asim. / kurtosis)

4.3 Inferencia

- Error tipo I = $P(\text{rechazo } H_0 | H_0)$, tipo II = $P(\text{Acepto } H_0 | H_1)$.
- ① Inferencia de β_j - homocedasticidad + normalidad
 - $H_0: \beta_j = 0$, $H_1: \beta_j \neq 0$
 - $t = \frac{\hat{\beta}_j}{ee(\hat{\beta}_j)} \sim t_{n-(k+1)}$ bajo homoc. + normalidad, i.e. $\varepsilon_i \sim N(0, \sigma^2) \forall i$.
 - Si hacemos $H_1: \beta_j \neq 0$ utilizamos $|t| > t_{n-k-1, \alpha/2}$ 
 - Si hacemos $H_1: \beta_j > 0$ utilizamos $t > t_{n-k-1, \alpha}$
- p-valor = $P(\text{observar nuestros datos} | H_0)$.

② Inferencia de β_j - hetero. + no normalidad

- $\frac{\hat{\beta}_j - \beta_j}{ee(\hat{\beta}_j)} \xrightarrow{d} N(0, 1)$ así que hacer contrastes asintóticos.

③ contraste de hipótesis de conjunto: F

- $H_0: \beta_{k-q+1} = \beta_{k-q+2} = \dots = \beta_k = 0$
 $H_1: \text{al menos una } \neq 0$.
- Ecuac. irrestrictiva $y_i = \beta_0 + \dots + \beta_k x_{ki} + \varepsilon_i \in \mathbb{R}$
Ecuac. restringida $y_i = \beta_0 + \dots + \beta_{k-q} x_{(k-q)i} + \varepsilon_i \in \mathbb{R}$
- Homocedasticidad y normalidad
- $\frac{(SCR_R - SCR_{NR})/q}{SCR_{NR}/(n-k-1)} \sim F_{q, n-k-1}$ \rightarrow 
Rechazamos si $> F_{q, n-k-1, \alpha}$.
 Nota: $SCR = \sum_{i=1}^n \hat{\varepsilon}_i^2$
- Heterocedasticidad
- $F^R_q \xrightarrow{d} \chi^2_q$ o $\frac{1}{q} F^R_q \rightarrow F_{q, \infty}$ cuando $n \rightarrow \infty$.

4.5 Predicción

- $\hat{y}^0 = \hat{\beta}_0 + \hat{\beta}_1 x_1^0 + \dots + \hat{\beta}_k x_k^0$ y $\hat{\varepsilon}^0 = y^0 - \hat{y}^0$
- por lo que $\text{var}(\hat{\varepsilon}^0 | x) = \underbrace{\text{var}(\varepsilon^0)}_{=\sigma^2} + \text{var}(\hat{y}^0) = \sigma^2 \approx \hat{\sigma}^2$ estimador insesgado.
- Podemos hacer un intervalo de confianza aprox del 95%:
 $\hat{y}^0 \pm 1.96 ee(\hat{\varepsilon}^0) \approx \hat{y}^0 \pm 2 \sqrt{ee(\hat{y}^0)^2 + \hat{\sigma}^2}$

Tema 6 - Regresión con Heterocedasticidad y Autocorr

6.1 Heterocedasticidad

• Recuerda que incluso en este supuesto $\hat{\beta}_{MCO}$ es insesgado y consistente, pero ineficiente en general.

$$\Sigma_{\varepsilon\varepsilon'} := E[\varepsilon\varepsilon'|X] = \begin{pmatrix} \sigma_1^2 & & 0 \\ & \ddots & \\ 0 & & \sigma_n^2 \end{pmatrix}$$

$$\Rightarrow \hat{\beta}_{MCP} = (X^T \Sigma_{\varepsilon\varepsilon'}^{-1} X)^{-1} X^T \Sigma_{\varepsilon\varepsilon'}^{-1} y$$

↳ Mínimos cuadrados ponderados (i.e. simplemente multiplicamos por $1/\sigma_i$ para hacer todo homocedástico).

• Normalmente no conocemos σ_i así que utilizamos $\hat{\beta}_{MCO}$.

Contrastes de heterocedasticidad

↳ Supón que $\varepsilon_i^2 = \alpha_0 + \alpha_1 X_{i1} + \dots + \alpha_k X_{ik} + e_i$
entonces $H_0: \text{var}(\varepsilon_i) = \sigma^2 \Leftrightarrow H_0: \alpha_1 = \dots = \alpha_k = 0$.

En la práctica regresamos $\hat{\varepsilon}_i^2 = \alpha_0 + \dots + \alpha_k X_{ik} + e_i$
y calculamos el estadístico $F = \frac{R^2/k}{(1-R^2)/(n-k-1)} \sim F_{k, n-k-1}$.

① Contraste de Breusch-Pagan (BP)

$$LM = n \cdot R^2 \sim \chi^2_k$$

② contraste de White = calcula el LM pero en la regresión de $\hat{\varepsilon}_i^2$ se incluyen cuadrados (i.e. X_{ji}^2) y efectos cruzados (i.e. $X_{ji}X_{lc}$).

6.2 Autocorrelación

$$\hookrightarrow E[\varepsilon_s \varepsilon_j | X] \neq E[\varepsilon_s | X] E[\varepsilon_j | X]$$

① contraste de Durbin-Watson (DW)

$$DW = \frac{\sum_{t=1}^T (\hat{\varepsilon}_t - \hat{\varepsilon}_{t-1})^2}{\sum_{t=1}^T \hat{\varepsilon}_t^2} \approx 2(1 - \hat{\rho})$$

$$\hat{\varepsilon}_t = \hat{\rho} \hat{\varepsilon}_{t-1} + e_t$$

↑
Autocorrel. de primer orden.

si no hay autocorr. $DW \approx 2$ ya que $\hat{\rho} \approx 0$.

↓
En las tablas ofrecen valores inferiores y superiores d_L, d_U . Hay dos casos:

$DW < 2$ ① $\alpha_0: \hat{\rho} = 0$
 $\alpha_1: \hat{\rho} > 0$ }

$DW > 2$ ② $\alpha_0: \hat{\rho} = 0$
 $\alpha_1: \hat{\rho} < 0$ }

i.e. en general

Tema 7 - Variables Explicativas Dicotómicas

7.1 Modelos ANOVA - análisis de varianzas.

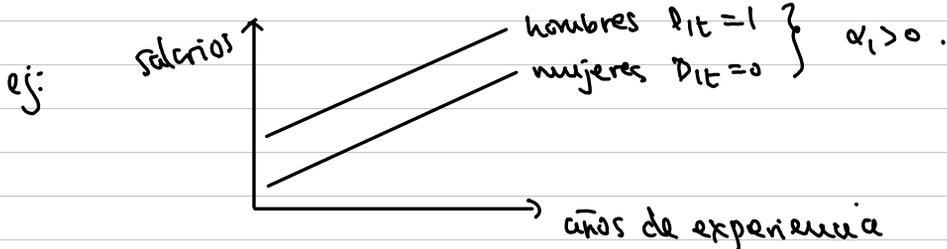
- $y_i = \beta_0 + \alpha_1 D_{i1} + \dots + \alpha_m D_{im} + \varepsilon_i$, hay m variables Dummy, e. $D_{ik} \in \{0, 1\}$.

ej: si tenemos $y_i = \text{salarios}$ y queremos incluir el nivel de estudio $\in \{1, 2, \dots, 8\}$, utilizamos 7 variables dummy (no 8 porque sino habrá multicolinealidad: $\sum D_k = 1 \Rightarrow$ "trampa de la var. dummy")

- Si $\alpha_i = \alpha_j$ podemos hacer el contraste $\chi_0: \alpha_i - \alpha_j = 0$ utilizando el estadístico $\left| \frac{\hat{\alpha}_i - \hat{\alpha}_j}{\sigma(\hat{\alpha}_i - \hat{\alpha}_j)} \right| > t_{n-k-1, \alpha/2}$.

7.2 Modelos ANCOVA - inclusiones dummy y cuantitativas

- Ejemplo $y_t = \beta_0 + \beta_1 X_{it} + \alpha_1 D_{it} + \varepsilon_t$.



7.3 Interacciones

- Se pueden incluir cosas como $\alpha_1 D_{it} X_{it}$ lo cual hace que la pendiente cambie.

7.4 Estacionalidad - movimientos oscilante regular y repetitivo.

- Podemos desestacionalizar la serie haciendo una regresión tipo ANOVA, ej: $y_t = \alpha_1 D_{1t} + \dots + \alpha_{12} D_{12t} + \varepsilon_t$ y luego analizar $y_t - \hat{y}_t$, la cual no debería tener estacionalidad.

7.5 Regresión por tramos

- $y_i = \beta_0 + \alpha_0 D_{ii} + \beta_1 X_{ii} + \alpha_1 D_{ii} X_{ii} + \varepsilon_i$ y

$$\text{supón que } D_{ii} = \begin{cases} 0 & \text{si } X_{ii} \leq j^* \\ 1 & \text{si } X_{ii} > j^* \end{cases}$$

$$\Leftrightarrow \text{Dos regresiones } \begin{cases} y_i = \beta_0 + \beta_1 X_{ii} + \varepsilon_i & X_{ii} \leq j^* \\ y_i = \beta_0 + \alpha_0 + (\beta_1 + \alpha_1) X_{ii} + \varepsilon_i & X_{ii} > j^* \end{cases}$$

pero como tienen que coincidir en $X_{ii} = j^*$ vemos que $\alpha_0 = -\alpha_1 j^*$ por lo que obtenemos una regresión

$$y_i = \beta_0 + \beta_1 X_{ii} + \alpha_1 D_{ii} (X_{ii} - j^*) + \varepsilon_i$$

Tema 8 - Análisis de especificación

8.1 Selección de variables

- Inclusión de variables irrelevantes

$$- AIC = \ln \left(\frac{\sum_{i=1}^n \hat{\epsilon}_i^2}{n} \right) + \frac{2(k+1)}{n} \quad \leftarrow \text{se intenta penalizar más la adición de regresores.}$$

$$- Schwarz = \frac{k+1}{n} \ln(n) + \ln \left(\frac{\sum \hat{\epsilon}_i^2}{n} \right) \quad \leftarrow$$

- Efectos: $\hat{\beta}_j$ sigue siendo sesgado y inconsistente pero $se(\hat{\beta}_j)$ deja de ser eficiente.
- Utilizar contrastes tipo F sobre $\hat{\beta}_j$ o F sobre conjuntos para evitar la sobre-especificación.

- Omisión de variables relevantes

Los problemas de subespecificación son más graves: si la variable omitida es un factor determinante de y y está correl. con x_i entonces $\hat{\beta}_j$ no se vuelve insesgado \rightarrow sesgo de variable omitida.

$$\hat{\beta}_1 \xrightarrow{P} \beta_1 + \rho_{x\epsilon} \frac{\sigma_\epsilon \sigma_x}{\sigma_x^2} \quad \text{por lo que si } \text{cov}(x, \epsilon) \neq 0 \text{ problema!}$$

Podemos incluir variables de control para mantener la insesgadez del resto de estimadores.

8.2 Mala especificación funcional

- Contraste RESET

$$y_i = \beta_0 + \dots + \beta_k x_{ki} + \delta_1 \hat{y}_i^2 + \delta_2 \hat{y}_i^3 + \epsilon_i$$

\hat{y}_i : valores ajustados a la ecuación normal.

Contrastamos $H_0: \delta_1 = \delta_2 = 0$. Hacemos un contraste tipo F o LM $\sim \chi^2_2$.

- Modelos no anidados: comparamos modelos que no están incluidos uno en otro, ej: comparamos el día con $y_i = \beta_0 + \dots + \beta_k z_{ki} + \epsilon_i$ (en vez de x_{ki}).

① Hacer $y_i = \sum \delta_j x_{ji} + \sum \alpha_j z_{ji} + \epsilon_i$ y hacer contraste F con $H_0: \alpha_j = 0 \forall j$.

② "Prueba J"

$y_i = \sum \beta_j x_{ji} + \phi_1 \hat{y}_i^2 + \epsilon_i$ y contrastar $H_0: \phi_1 = 0$. Si significativo rechazamos el modelo $y_i = \sum \beta_j x_{ji} + \epsilon_i$. Hacemos lo mismo con \hat{y}_i^3 .

8.3 Errores de medida

- Supón que y_i^* es la variable sin errores de medición y que medimos $y_i = y_i^* + w_i$. Entonces si regresamos $y_i = \beta_0 + \dots + \beta_k x_{ki} + \epsilon_i + w_i$ encontramos que $\text{plim } \hat{\beta}_1 = \frac{\text{cov}(x, y^*) + \text{cov}(x, w)}{\text{var}(x)} = \beta_1$ si

$\text{cov}(x, w) = 0$. El único problema será que la varianza será mayor.

- También hay errores en la variable explicativa ($x_i = x_i^* + w_i$). Existen dos posibles escenarios:

① $\text{cov}(x_i, w_i) = 0$
 $\hat{\beta}_1$ es consistente pero la varianza es mayor.

② $\text{cov}(x_i^*, w_i) = 0 \Rightarrow \text{cov}(x_i, w_i) = \sigma_w^2 \neq 0$.
 $\hat{\beta}_1$ es inconsistente e infraestimada, i.e. $|\hat{\beta}_1| < |\beta_1|$

Ade más los demás estimadores $\hat{\beta}_j$ se vuelven inconsistentes.

- Variables proxy: no podemos medir la variable exógena, ej. coef. intelectual, y utilizamos una var. que la aprox., ej. nivel de estudios.

$$x_i^*: \text{inobservable}, x_i: \text{proxy}, x_i^* = \delta_0 + \delta_1 x_i + \epsilon_i$$

- sustituimos x_i^* por x_i : "sol^o por sust. de var. omitida".
- utilizar lógica sust. para ver cuando serán inconsistentes: ver exogeneidad.

8.4 otras fuentes de invalidez

- Problemas de selección muestral, i.e. datos perdidos.
- Causalidad simultánea \Rightarrow no podemos asumir que $\text{cov}(x_i, \epsilon_i) = 0$.
- Errores estándares inconsistentes (i.e. por tratamiento inapropiado de heterocedasticidad).

$$\rightarrow y_i = \beta_0 + \beta_1 x_i + \epsilon_i \Rightarrow \text{cov}(x_i, \epsilon_i) = \frac{\sigma_1 \sigma_\epsilon^2}{1 - \sigma_1 \beta_1}$$

$$x_i = \delta_0 + \delta_1 y_i + v_i$$

Da lugar a un MCO sesgado e inconsistente.

Resumen Importante

- Contraste global
 $\chi_0: \beta_0 = \dots = \beta_k = 0$

$$F_{k, n-k-1} = \frac{R^2/k}{(1-R^2)/(n-k-1)}$$

- Contraste algunas β_i
 $\chi_0: \beta_{i_1} = \dots = \beta_{i_q} = 0$

$$F_{q, n-k-1} = \frac{(SCR_k - SCR_{NR})/q}{SCR_{NR}/(n-k-1)}$$