

Modelos Lineales de Regresión

El Modelo

$$\tilde{y}_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \tilde{\varepsilon}_i$$

$$\begin{bmatrix} \tilde{y}_1 \\ \tilde{y}_2 \\ \vdots \\ \tilde{y}_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{21} & \dots & x_{k1} \\ 1 & x_{12} & x_{22} & \dots & x_{k2} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{1n} & x_{2n} & \dots & x_{kn} \end{bmatrix} \cdot \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} \tilde{\varepsilon}_1 \\ \tilde{\varepsilon}_2 \\ \vdots \\ \tilde{\varepsilon}_n \end{bmatrix}$$

$$\tilde{\mathbf{y}} = \mathbf{X} \boldsymbol{\beta} + \tilde{\boldsymbol{\varepsilon}}$$

n datos
p=k+1 parámetros


Supuestos

S1) $E\tilde{\boldsymbol{\varepsilon}} = 0$

S2 / S3) $V\tilde{\boldsymbol{\varepsilon}} = \sigma^2 I$

S4) $\tilde{\boldsymbol{\varepsilon}} : \text{Normal}$

S5) $\text{Rango}(X) = p$



Estimación

$$\tilde{y} = Xb + \tilde{e}$$

$$b = ({}^tXX)^{-1}{}^tXy = \mathfrak{J}^{-1}{}^tXy$$

$$\hat{\sigma}^2 = \frac{1}{n}{}^tee$$

Matriz de Proyección

$$\hat{y} = Xb = X(tXX)^{-1}tXy = Hy$$

con $H = X(tXX)^{-1}tX$ Matriz de proyección

Propiedades de la matriz de proyección

Es simétrica

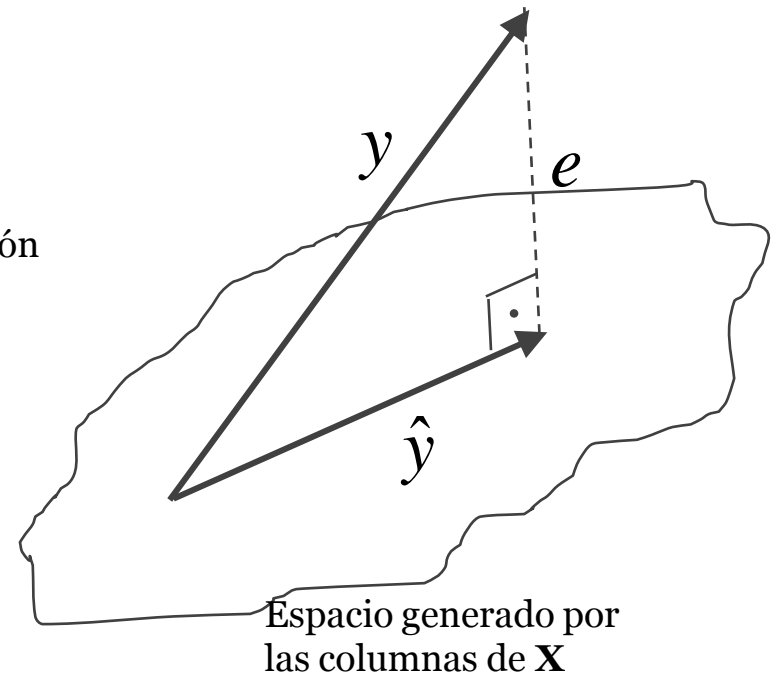
Es idempotente, luego es semidefinida positiva con valores propios: 0 o 1.

$$e = y - \hat{y} = y - Hy = (I - H)y$$

$$tXe = tX(I - H)y = (tX - tXX(tXX)^{-1}tX)y = 0$$

entonces los residuos suman 0.

Además: $\frac{1}{n} \leq h_{ii} \leq 1$



Análisis de la Varianza

$$\hat{y} = Hy$$

$$e = (I - H)y$$

$$y = \hat{y} + e$$

$$\begin{aligned} {}^t yy &= {}^t (\hat{y} + e)(\hat{y} + e) \\ &= {}^t \hat{y}\hat{y} + 2{}^t \hat{y}e + {}^t ee \\ &= {}^t \hat{y}\hat{y} + 2{}^t yH(I - H)y + {}^t ee \\ &= {}^t \hat{y}\hat{y} + 2{}^t y(H - H^2)y + {}^t ee = {}^t \hat{y}\hat{y} + {}^t ee \end{aligned}$$

Haciendo este desarrollo sobre la suma de cuadrados centrada se obtiene:

$$\boxed{Q_T = Q_E + Q}$$

Propiedades de los Estimadores

Ausencia de Sesgo

$$E\tilde{b} = E(\mathfrak{T}^{-1t} X\tilde{y}) = \mathfrak{T}^{-1t} XE\tilde{y} = \mathfrak{T}^{-1t} XX\beta = \beta$$

Varianza

$$V\tilde{b} = V(\mathfrak{T}^{-1t} X\tilde{y}) = \mathfrak{T}^{-1t} XV\tilde{y}X\mathfrak{T}^{-1} = \mathfrak{T}^{-1t} X\sigma^2 IX\mathfrak{T}^{-1} = \mathfrak{T}^{-1t} XX\mathfrak{T}^{-1}\sigma^2 = \mathfrak{T}^{-1}\sigma^2$$

Teorema de Gauss-Markov

\tilde{b} es BLUE

Propiedades de los Estimadores

Otras

$$Es^2 = \sigma^2 \quad \text{donde: } s^2 = \frac{1}{v} {}^t ee, \quad v = n - p$$

\tilde{b} y \tilde{s}^2 independientes

\tilde{b} y \tilde{s}^2 suficientes

\tilde{b} : *Normal*

$$\frac{v\tilde{s}^2}{\sigma^2} : \chi_v^2$$

Inferencia

Sobre β

$$\begin{aligned}\tilde{b}_j : \text{Normal}(\beta_j, \mathfrak{I}^{jj} \sigma^2) &\Rightarrow \frac{(\tilde{b}_j - \beta_j)^2}{\mathfrak{I}^{jj} \sigma^2} : \chi_1^2 \\ &\Rightarrow \frac{(\tilde{b}_j - \beta_j)^2}{\mathfrak{I}^{jj} s^2} : F_{1, \nu}\end{aligned}$$

Inferencia

Sobre $E(\tilde{y} / x_0) = {}^t x_0 \beta$

$$\hat{y} / x_0 = {}^t x_0 b : Normal({}^t x_0 \beta, \sigma^2 {}^t x_0 \mathfrak{I}^{-1} x_0)$$
$$\Rightarrow \frac{\hat{y} / x_0 - E(\tilde{y} / x_0)}{\sqrt{{}^t x_0 \mathfrak{I}^{-1} x_0} s} : t_v$$

Predicción de $\tilde{y} / x_0 = {}^t x_0 \beta + \tilde{\varepsilon}$

$$V(\hat{y} / x_0 - \tilde{y} / x_0) = V(\hat{y} / x_0) + V(\tilde{y} / x_0) = {}^t x_0 \mathfrak{I}^{-1} x_0 \sigma^2 + \sigma^2$$
$$\Rightarrow \frac{\hat{y} / x_0 - \tilde{y} / x_0}{\sqrt{1 + {}^t x_0 \mathfrak{I}^{-1} x_0} s} : t_v$$

Incumplimiento de Supuestos

Análisis de Residuos

- ♦ Es la técnica mas potente para diagnosticar el incumplimiento de supuestos.

$$e = (I - H)y \Rightarrow \begin{cases} Ve_i = (1 - h_{ii})\sigma^2 \\ V(e_i; e_l) = -h_{il}\sigma^2 \end{cases}$$

- ♦ Residuos Studentizados:

$$r_i = \frac{e_i}{s\sqrt{1 - h_{ii}}}$$

- ♦ Residuos PRESS:

$$e_{-i,i} = y_i - \hat{y}_{-i,i} = \frac{e_i}{1 - h_{ii}}$$

- ♦ Residuos Externamente Studentizados:

$$t_i = \frac{e_i}{s_{-i}\sqrt{1 - h_{ii}}} \quad s_{-i}^2 = \frac{1}{v-1} \left(v s^2 - \frac{e_i^2}{1 - h_{ii}} \right)$$

Incumplimiento de Supuestos Anormalidad

- ◆ Diagnóstico:
 - » Analizar si los residuos studentizados siguen una distribución Normal
 - » Cuando la muestra es chica esto no se puede hacer pues: $e_i = \varepsilon_i - \sum h_{ij} \varepsilon_j$ tiende a normal por el TLC. Cuando es grande las h_{ij} tienden a 0, y $e_i \cong \varepsilon_i$
- ◆ Tratamiento:
 - » Regresión Robusta: Consiste en mochar los residuos en la suma de cuadrados, de manera de mitigar la influencia de los outliers. Se resuelve por regresión ponderada.

Incumplimiento de Supuestos Heterocedasticidad

- ◆ Diagnóstico:

- » Se observa la dispersión de los residuos en función de y , y de cada x_j .

- ◆ Tratamiento:

- » Regresión ponderada:

$$V\tilde{\varepsilon} = \sigma^2 V$$

$$b = \mathfrak{S}^{-1} {}^t X V^{-1} y \quad \text{con} \quad \mathfrak{S} = {}^t X V^{-1} X$$

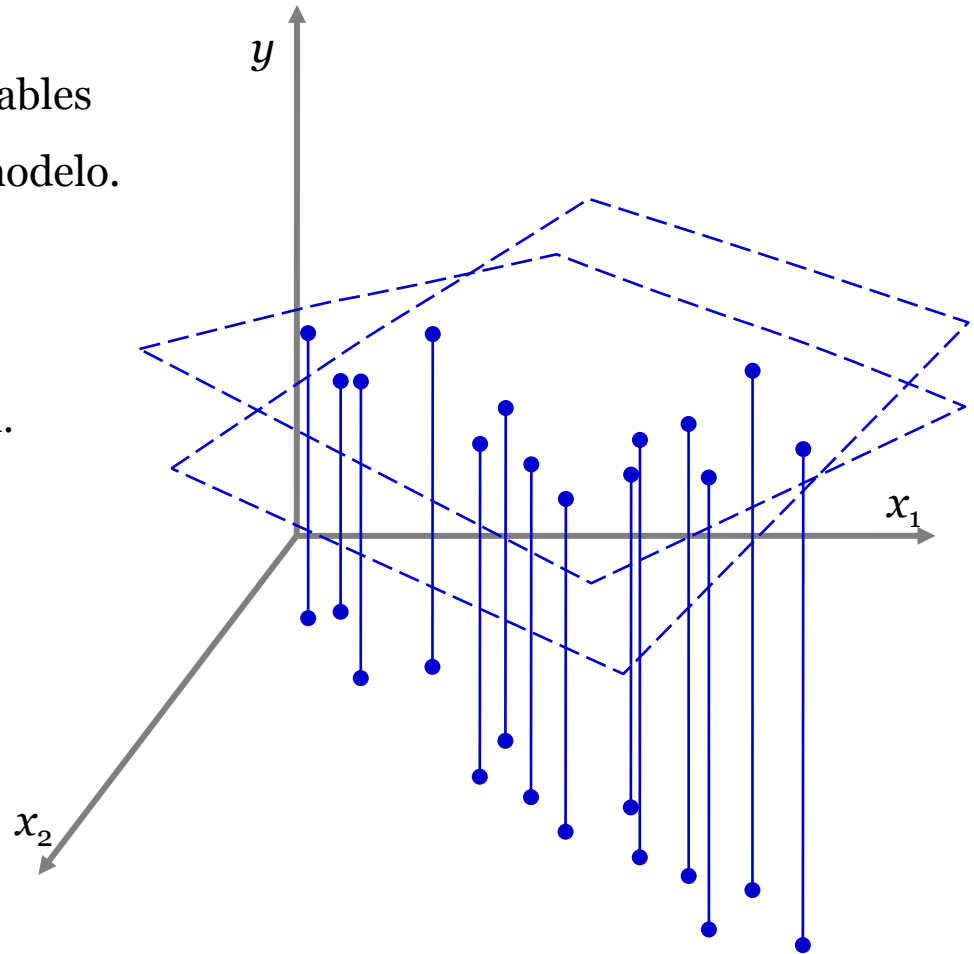
- » Transformaciones:

- Box & Cox:

$$y' = \begin{cases} \frac{1}{\lambda}(y^\lambda - 1) & \lambda \neq 0 \\ \ln y & \lambda = 0 \end{cases}$$

Incumplimiento de Supuestos Colinealidad


- ♦ Las relaciones lineales entre las variables explicativas son deletéreas para el modelo.
 - » Desestabilizan los coeficientes.
 - » Zonas de predicción inestable.
 - » Puede ser poblacional o muestral.
- ♦ Diagnóstico:
 - $\det(\mathfrak{I}_E) < 0.1$
 - $VIF_j = \mathfrak{I}_E^{jj} > 10$
- ♦ Tratamiento:
 - » Sacar variables o agregar datos.
 - » Ridge estimation.
 - » Componente principales.



Incumplimiento de Supuestos Autocorrelación

- ♦ Se puede producir cuando los datos están ordenados: i es el tiempo.
- ♦ Diagnóstico:
 - » Se observan tendencias cíclicas en los residuos en función de i .
 - » Ensayo de Durbin-Watson:

$$H_0) \rho_1 = 0$$
$$d_k = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2}$$



- No es válido cuando hay variables endógenas rezagadas.
- ♦ Tratamiento:
 - » Series de tiempo.

Modelización

- ♦ Objetivo: Encontrar un modelo parsimonioso que ajuste bien a los datos.
- ♦ Indicadores de calidad del modelo:
 - » R^2 : mide el ajuste pero no la colinealidad.
 - » R^2 ajustado (varianzas en vez de Q) o s^2 : mide el ajuste y penaliza p , pero no la colinealidad.
 - » PRESS: mide la capacidad de predicción en el dominio de los datos. Detecta puntos influyentes pero no otros casos de colinealidad.
 - » det : Cuando es menor que 0.2 detecta colinealidad.
 - » C_p : Cuando supera p detecta sesgo por sub-especificación o bien colinealidad por sobre-especificación. Es un indicador volátil.