

Modelos Lineales y Modelos Lineales Generalizados

Plano de esta parte.

- ▶ Modelos lineales.
- ▶ Familias Exponenciales de Distribuciones.
- ▶ Modelos Lineales Generalizados.

Modelos Lineales

Un modelo lineal tiene la forma:

$$\mathbf{Y} = \mathbf{x}\beta + \epsilon.$$

- ▶ \mathbf{Y} : $n \times 1$ vector de variables de respuesta.
- ▶ \mathbf{x} : $n \times p$ matriz de variables explicativas, típicamente con la primera columna constante y igual a 1.
- ▶ β : $p \times 1$ vector de parámetros.

$$\beta = (\beta_1, \dots, \beta_p)'$$

- ▶ ϵ : $n \times 1$ vector de errores normales, idénticos y independientes (i.i.d.). Luego

$$\epsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I}),$$

donde \mathbf{I} es la matriz de identidad de tamaño n .

- ▶ $\mathbb{E}(\mathbf{Y}) = \mathbf{x}\beta$.

Supuestos de Modelos Lineals

Linealidad: los observaciones se relacionan linealmente con los parámetros del modelo.

Normalidad: los errores son normales.

Independencia: los Errores son independientes.

Homocedástico: todos los errores tienen la misma varianza.

Ajustando un Modelo Lineal

- ▶ Se estima los parámetros β por el método de mínimos cuadrados. Es equivalente al método de estimación por máxima verosimilitud cuando los errores son normales.
- ▶ La densidad de un variable Y que es normal con media μ y varianza σ^2 es $f_Y(y; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-\mu)^2}{2\sigma^2}}$.
- ▶ La función de verosimilitud para $\mathbf{Y} = \mathbf{y}$ del modelo lineal es

$$\begin{aligned}L(\beta, \sigma^2 \mid \mathbf{y}) &= \prod_{i=1}^n f_Y(y_i; (\mathbf{x}\beta)_i, \sigma^2) \\&= (2\pi\sigma^2)^{-n/2} \prod_{i=1}^n e^{-(y_i - (\mathbf{x}\beta)_i)^2 / 2\sigma^2} \\&= (2\pi\sigma^2)^{-n/2} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - (\mathbf{x}\beta)_i)^2} \\&= \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n e^{-(1/2\sigma^2)(\mathbf{y} - \mathbf{x}\beta)'(\mathbf{y} - \mathbf{x}\beta)}.\end{aligned}$$

El Estimador $\hat{\beta}$

- ▶ El log de la verosimilitud es

$$\log L(\beta, \sigma^2 | \mathbf{y}) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{x}\beta)' (\mathbf{y} - \mathbf{x}\beta).$$

- ▶ Elegir la $\hat{\beta}$ que Maximiza el log de la verosimilitud es equivalente a elegir la $\hat{\beta}$ que minimiza

$$(\mathbf{y} - \mathbf{x}\beta)' (\mathbf{y} - \mathbf{x}\beta).$$

$$\begin{aligned} \frac{d}{d\beta} (\mathbf{y} - \mathbf{x}\beta)' (\mathbf{y} - \mathbf{x}\beta) &= \mathbf{0} \\ \iff \frac{d}{d\beta} (\mathbf{y}'\mathbf{y} - 2\beta'\mathbf{x}'\mathbf{y} + \beta'\mathbf{x}'\mathbf{x}\beta) &= \mathbf{0} \\ \iff \mathbf{x}'\mathbf{x}\beta - \mathbf{x}'\mathbf{y} &= \mathbf{0} \\ \implies \hat{\beta} &= (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{y}. \end{aligned}$$

- ▶ La media de $\hat{\beta}$ es

$$\begin{aligned} \mathbb{E}(\hat{\beta}) &= \mathbb{E}((\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{Y}) \\ &= (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{x}\beta = \beta. \end{aligned}$$

El Estimador $\hat{\beta}$ (2)

► $\hat{\beta}$ es un estimador sin sesgo: $\mathbb{E}(\hat{\beta} - \beta) = \beta - \beta = \mathbf{0}$.

► Matriz de covarianza:

$$\begin{aligned}\text{cov}(\hat{\beta}) &= \mathbb{E} \left((\hat{\beta} - \mathbb{E}(\hat{\beta})) (\hat{\beta} - \mathbb{E}(\hat{\beta}))' \right) \\ &= \mathbb{E} \left((\hat{\beta} - \beta) (\hat{\beta} - \beta)' \right).\end{aligned}$$

Pero

$$\begin{aligned}\hat{\beta} - \beta &= (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{Y} - (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{x}\beta \\ &= (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'(\mathbf{Y} - \mathbf{x}\beta).\end{aligned}$$

Luego

$$\begin{aligned}\text{cov}(\hat{\beta}) &= \mathbb{E} \left((\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'(\mathbf{Y} - \mathbf{x}\beta)(\mathbf{Y} - \mathbf{x}\beta)'\mathbf{x}(\mathbf{x}'\mathbf{x})^{-1} \right) \\ &= (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbb{E} \left((\mathbf{Y} - \mathbf{x}\beta)(\mathbf{Y} - \mathbf{x}\beta)' \right) \mathbf{x}(\mathbf{x}'\mathbf{x})^{-1} \\ &= (\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\sigma^2\mathbf{I}\mathbf{x}(\mathbf{x}'\mathbf{x})^{-1} \\ &= \sigma^2(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{x}(\mathbf{x}'\mathbf{x})^{-1} = \sigma^2(\mathbf{x}'\mathbf{x})^{-1}.\end{aligned}$$

► $\hat{\beta} \sim N(\beta, \sigma^2(\mathbf{x}'\mathbf{x})^{-1})$.

Estimando σ^2

- ▶ Para obtener un estimador de σ^2 , solucionamos

$$\frac{d}{d\sigma^2} \left(\frac{n}{2} \log(2\pi\sigma^2) \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{x}\beta)'(\mathbf{y} - \mathbf{x}\beta) \right) = 0.$$

El estimador de σ^2 que obtenemos es:

$$\hat{\sigma}^2 = \frac{1}{n} (\mathbf{Y} - \mathbf{X}\hat{\beta})'(\mathbf{Y} - \mathbf{X}\hat{\beta}).$$

- ▶ Veremos que $\hat{\sigma}^2$ es sesgado.

Valores Ajustados

- ▶ Valores ajustados:

$$\hat{\mathbf{Y}} = \mathbf{x}\hat{\beta} = \mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{Y} = \mathbf{h}\mathbf{Y},$$

donde $\mathbf{h} = \mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'$ es la matriz de predicción.

- ▶ Se lo denota \mathbf{h} porque en Inglés se llama “the hat matrix”:

$$\mathbf{Y} \xrightarrow{\mathbf{h}} \hat{\mathbf{Y}}.$$

- ▶ $\hat{\mathbf{Y}}$ Representa los valores de las observaciones predichos por el modelo ajustado.



$$\begin{aligned}\mathbb{E}(\hat{\mathbf{Y}}) &= \mathbb{E}(\mathbf{h}\mathbf{Y}) = \mathbf{h}\mathbb{E}(\mathbf{Y}) = \mathbf{h}\mathbf{x}\beta \\ &= \mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{x}\beta = \mathbf{x}\beta = \mathbb{E}(\mathbf{Y}).\end{aligned}$$

- ▶ $\text{cov}(\hat{\mathbf{Y}}) = \text{cov}(\mathbf{h}\mathbf{Y}) = \mathbf{h}\text{cov}(\mathbf{Y})\mathbf{h}' = \sigma^2\mathbf{h}\mathbf{h}' = \sigma^2\mathbf{h}^2 = \sigma^2\mathbf{h}$
porque \mathbf{h} es una proyección: $\mathbf{h} = \mathbf{h}'$ y

$$\mathbf{h}^2 = \mathbf{h}\mathbf{h} = \mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}' = \mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}' = \mathbf{h}.$$

- ▶ $\hat{\mathbf{Y}} \sim N(\mathbf{x}\beta, \sigma^2\mathbf{h})$.

Los Residuos

- ▶ Residuos: $\mathbf{R} = \mathbf{Y} - \hat{\mathbf{Y}} = (\mathbf{I} - \mathbf{h})\mathbf{Y}$.
- ▶ $\mathbb{E}(\mathbf{R}) = \mathbb{E}(\mathbf{Y}) - \mathbb{E}(\hat{\mathbf{Y}}) = \mathbf{x}\beta - \mathbf{x}\beta = \mathbf{0}$.
- ▶ Matriz de covarianzas:

$$\begin{aligned}\text{cov}(\mathbf{R}) &= \text{cov}((\mathbf{I} - \mathbf{h})\mathbf{Y}) \\ &= (\mathbf{I} - \mathbf{h})\text{cov}(\mathbf{Y})(\mathbf{I} - \mathbf{h})' \\ &= (\mathbf{I} - \mathbf{h})\sigma^2\mathbf{I}(\mathbf{I} - \mathbf{h})' \\ &= \sigma^2(\mathbf{I} - \mathbf{h})^2 = \sigma^2(\mathbf{I} - 2\mathbf{h} + \mathbf{h}) = \sigma^2(\mathbf{I} - \mathbf{h}).\end{aligned}$$

- ▶ Lo mismo que \mathbf{h} , $\mathbf{I} - \mathbf{h}$ es simétrico y es una proyección también.
- ▶ $\mathbf{R} \sim N(\mathbf{0}, \sigma^2(\mathbf{I} - \mathbf{h}))$.

El Estimador $\hat{\sigma}_2$

- ▶ $\hat{\sigma}^2$ es un múltiplo de la suma de los residuos cuadráticos:

$$\begin{aligned}\hat{\sigma}^2 &= \frac{1}{n}(\mathbf{Y} - \mathbf{x}\hat{\beta})'(\mathbf{Y} - \mathbf{x}\hat{\beta}) \\ &= \frac{1}{n}(\mathbf{Y} - \hat{\mathbf{Y}})'(\mathbf{Y} - \hat{\mathbf{Y}}) = \frac{1}{n}\mathbf{RR}'.\end{aligned}$$

- ▶ También,

$$\begin{aligned}(\mathbf{Y} - \hat{\mathbf{Y}})'(\mathbf{Y} - \hat{\mathbf{Y}}) &= (\mathbf{Y} - \mathbf{x}\beta - \mathbf{h}(\mathbf{Y} - \mathbf{x}\beta))'(\mathbf{Y} - \mathbf{x}\beta - \mathbf{h}(\mathbf{Y} - \mathbf{x}\beta)) \\ &= (\mathbf{Y} - \mathbf{x}\beta)'(\mathbf{I} - \mathbf{h})'(\mathbf{I} - \mathbf{h})(\mathbf{Y} - \mathbf{x}\beta) \\ &= (\mathbf{Y} - \mathbf{x}\beta)'(\mathbf{I} - \mathbf{h})(\mathbf{Y} - \mathbf{x}\beta) \\ &= \sum_{i=1}^n \sum_{j=1}^n (1 - h_{ij})(Y_i - (\mathbf{x}\beta)_i)(Y_j - (\mathbf{x}\beta)_j).\end{aligned}$$

La Esperanza de $\hat{\sigma}^2$

- ▶ Tomando la esperanza, obtenemos

$$\begin{aligned}\mathbb{E} \left((\mathbf{Y} - \hat{\mathbf{Y}})' (\mathbf{Y} - \hat{\mathbf{Y}}) \right) &= \sum_{i=1}^n \sum_{j=1}^n (1 - h_{ij}) \mathbb{E} \left((Y_i - (\mathbf{x}\beta)_i) (Y_j - (\mathbf{x}\beta)_j) \right) \\ &= \sigma^2 \sum_{i=1}^n (1 - h_{ii}) = \sigma^2 (n - \text{tr}(\mathbf{h})),\end{aligned}$$

donde $\text{tr}(\mathbf{h}) = \sum_{i=1}^n h_{ii}$ es la traza del matriz \mathbf{h} .

Propiedades de la Traza.

Para dos matrices \mathbf{a} y \mathbf{b} , y un constante c ,

$$\begin{aligned}\text{tr}(\mathbf{a} + \mathbf{b}) &= \text{tr}(\mathbf{a}) + \text{tr}(\mathbf{b}), \\ \text{tr}(c\mathbf{a}) &= c \text{tr}(\mathbf{a}), \\ \text{tr}(\mathbf{a}') &= \text{tr}(\mathbf{a}), \text{ y } \text{tr}(\mathbf{ab}) = \text{tr}(\mathbf{ba}).\end{aligned}$$

El Estimador S^2

- ▶ Luego

$$\text{tr}(\mathbf{h}) = \text{tr}(\mathbf{x}(\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}') = \text{tr}((\mathbf{x}'\mathbf{x})^{-1}\mathbf{x}'\mathbf{x}) = \text{tr}(\mathbf{I}_p) = p.$$

- ▶ La esperanza de $\hat{\sigma}^2$ es

$$\mathbb{E}(\hat{\sigma}^2) = \frac{n-p}{n}\sigma^2 < \sigma^2.$$

- ▶ Por eso, se define S^2 , un estimador de σ^2 que es sin sesgo:

$$S^2 = \frac{1}{n-p}(\mathbf{Y} - \mathbf{x}\beta)'(\mathbf{Y} - \mathbf{x}\beta) = \frac{n}{n-p}\hat{\sigma}^2.$$

$$\mathbb{E}(S^2) = \mathbb{E}\left(\frac{n}{n-p}\hat{\sigma}^2\right) = \frac{n}{n-p} \cdot \frac{n-p}{n}\sigma^2 = \sigma^2.$$

- ▶ $S^2(\mathbf{x}'\mathbf{x})^{-1}$, $S^2\mathbf{h}$ y $S^2(\mathbf{I} - \mathbf{h})$ son estimadores sin sesgo de $\text{cov}(\hat{\beta})$, $\text{cov}(\hat{\mathbf{Y}})$ y $\text{cov}(\mathbf{R})$ respectivamente.