

## Cuadrados mínimos: errores correlacionados y ajuste lineal

Tenemos  $n$  mediciones  $\{x_i, y_i\}$ , sin errores en  $x$  y errores gaussianos correlacionados en  $y$ . O sea, los  $y_i$  son variables aleatorias con distribución multinormal,  $\mathcal{N}(\mathbf{y} | \boldsymbol{\mu}, \mathbf{V})$ , con  $\boldsymbol{\mu}$  la esperanza de  $\mathbf{y}$ , y  $\mathbf{V}$  la matriz de covarianza de  $n \times n$ . La esperanza  $\mu_i = E(y_i) = f(x_i; \boldsymbol{\theta})$  depende de  $x_i$  y de los  $k$  parámetros  $\boldsymbol{\theta}$  que queremos estimar.

Maximizar la verosimilitud  $\mathcal{L}(\boldsymbol{\theta} | \mathbf{y})$  es lo mismo que minimizar la suma de cuadrados  $S(\boldsymbol{\theta})$ :

$$\begin{aligned}\mathcal{L}(\boldsymbol{\theta} | \mathbf{y}) &= \frac{1}{\sqrt{(2\pi)^n |\mathbf{V}|}} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right\} \\ \ln \mathcal{L}(\boldsymbol{\theta} | \mathbf{y}) &= -\frac{1}{2} \ln(2\pi)^n |\mathbf{V}| - \frac{1}{2} S(\boldsymbol{\theta}) \\ S(\boldsymbol{\theta}) &= (\mathbf{y} - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \quad \text{con } \mu_i = E(y_i) = f(x_i, \boldsymbol{\theta})\end{aligned}$$

Un caso particularmente importante es cuando la función a fitear es lineal en los parámetros,

$$f(x; \boldsymbol{\theta}) = \sum_{j=1}^k \theta_j f_j(x) \quad \text{siendo } f_j(x) \text{ funciones arbitrarias}$$

Evaluando  $f(x; \boldsymbol{\theta})$  en cada  $x_i$ ,

$$\mu_i = E(y_i) = f(x_i; \boldsymbol{\theta}) = \sum_{j=1}^k \theta_j f_j(x_i) = \sum_{j=1}^k A_{ij} \theta_j \quad \text{donde } \boxed{A_{ij} = f_j(x_i)}$$

Para el caso que la dependencia en los parámetros es lineal, queda  $\boldsymbol{\mu} = E(\mathbf{y}) = \mathbf{A} \boldsymbol{\theta}$ ,

$$\begin{aligned}S(\boldsymbol{\theta}) &= (\mathbf{y} - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \\ &= (\mathbf{y} - \mathbf{A} \boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A} \boldsymbol{\theta}) \\ &= (\mathbf{y}^T - \boldsymbol{\theta}^T \mathbf{A}^T) \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A} \boldsymbol{\theta}) \\ &= \mathbf{y}^T \mathbf{V}^{-1} \mathbf{y} - \mathbf{y}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta} - \boldsymbol{\theta}^T \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} + \boldsymbol{\theta}^T \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta}\end{aligned}$$

Para minimizar  $S(\boldsymbol{\theta})$  tenemos que encontrar los  $\hat{\boldsymbol{\theta}}$  que hacen  $\nabla S(\hat{\boldsymbol{\theta}}) = 0$  :

$$\mathbf{y}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta} \longrightarrow y_i V_{ij}^{-1} A_{jk} \theta_k \longrightarrow \frac{\partial(\quad)}{\partial \theta_m} = y_i V_{ij}^{-1} A_{jm} = A_{mj}^T V_{ji}^{-1} y_i = \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} \Big|_m$$

$$\boldsymbol{\theta}^T \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} \longrightarrow \theta_i A_{ij}^T V_{jk}^{-1} y_k \longrightarrow \frac{\partial(\quad)}{\partial \theta_m} = A_{mj}^T V_{jk}^{-1} y_k = \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} \Big|_m$$

$$\begin{aligned} \boldsymbol{\theta}^T \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta} \longrightarrow \theta_i A_{ij}^T V_{jk}^{-1} A_{kl} \theta_l &\longrightarrow \frac{\partial(\quad)}{\partial \theta_m} = A_{mj}^T V_{jk}^{-1} A_{kl} \theta_l + \theta_i A_{ij}^T V_{jk}^{-1} A_{km} \\ &= A_{mj}^T V_{jk}^{-1} A_{kl} \theta_l + \theta_i A_{ji} V_{kj}^{-1} A_{mk}^T \\ &= A_{mj}^T V_{jk}^{-1} A_{kl} \theta_l + A_{mk}^T V_{kj}^{-1} A_{ji} \theta_i = 2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta} \Big|_m \end{aligned}$$

$$\frac{\partial S}{\partial \theta_m} = -2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} \Big|_m + 2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta} \Big|_m \quad \Rightarrow \quad \nabla S(\boldsymbol{\theta}) = -2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} + 2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta}$$

$$\nabla S(\hat{\boldsymbol{\theta}}) = 0 \quad \Rightarrow \quad -2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} + 2 \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \hat{\boldsymbol{\theta}} = 0 \quad \Rightarrow \quad \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} = \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \hat{\boldsymbol{\theta}}$$

$$\hat{\boldsymbol{\theta}} = (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y}$$

La matriz de covarianza  $k \times k$  de los estimadores,  $\text{Cov}(\hat{\theta}_i, \hat{\theta}_j)$ , se obtiene a partir de la matriz de covarianza  $n \times n$  de los datos,  $\text{Cov}(y_r, y_s)$ . Es inmediato dado la relación lineal entre  $\boldsymbol{\theta}$  e  $\mathbf{y}$  :

$$\hat{\boldsymbol{\theta}} = \mathbf{C} \mathbf{y} \quad \text{con} \quad \mathbf{C} = (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1}$$

$$\begin{aligned} V(\hat{\boldsymbol{\theta}})_{ij} = \text{Cov}(\hat{\theta}_i, \hat{\theta}_j) &= \sum_{r,s} C_{ir} C_{js} \text{Cov}(y_r, y_s) \\ &= \sum_{r,s} C_{ir} \text{Cov}(y_r, y_s) C_{sj}^T \\ &= (\mathbf{C} \mathbf{V} \mathbf{C}^T)_{ij} \quad \Rightarrow \quad \mathbf{V}(\hat{\boldsymbol{\theta}}) = \mathbf{C} \mathbf{V} \mathbf{C}^T \end{aligned}$$

$$\mathbf{V}(\hat{\boldsymbol{\theta}}) = \mathbf{C} \mathbf{V} \mathbf{C}^T = \underbrace{(\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1}}_{\mathbf{C}} \mathbf{V} \underbrace{\mathbf{V}^{-1} \mathbf{A} (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1}}_{\mathbf{C}^T} = (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1}$$

$$\mathbf{V}(\hat{\boldsymbol{\theta}}) = (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1}$$

Los estimadores son no-sesgados :

$$\begin{aligned} E(\hat{\boldsymbol{\theta}}) &= E [(\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y}] \\ &= (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1} E(\mathbf{y}) \\ &= (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} \boldsymbol{\theta} = \boldsymbol{\theta} \end{aligned}$$

*Teorema de Gauss-Markov:* Entre todos los estimadores no sesgados, que son lineales en las observaciones, el estimador de cuadrados mínimos es el de menor varianza (pero es 100% eficiente sólo si los errores son gaussianos).

## Minimización $\chi^2$

Al método de cuadrados mínimos se los denomina también minimización  $\chi^2$  pues  $S(\mathbf{y}, \boldsymbol{\theta})$  es una variable aleatoria con distribución  $\chi_n^2$  cuando  $\mathbf{y}$  es multinormal de dimensión  $n$ .

$$\chi^2 : S(\mathbf{y}; \boldsymbol{\theta}) = (\mathbf{y} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A}\boldsymbol{\theta})$$

¿Qué ocurre si se reemplaza  $\boldsymbol{\theta}$  por sus estimadores  $\hat{\boldsymbol{\theta}}$ ?

$$\chi_{min}^2 : S(\mathbf{y}; \hat{\boldsymbol{\theta}}) = (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}})$$

Ahora  $S(\mathbf{y}; \hat{\boldsymbol{\theta}})$  no es más función de  $\boldsymbol{\theta}$ , es un estadístico función exclusiva de  $\mathbf{y}$ , aunque una función complicada ya que a su vez  $\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}(\mathbf{y})$ .

Un resultado importante es que  $S(\mathbf{y}; \hat{\boldsymbol{\theta}})$  tiene distribución  $\chi_{n-k}^2$ , donde  $k$  es el número de parámetros ajustados a partir de los  $n$  datos  $\mathbf{y}$ . O sea que por cada parámetro estimado de los datos, se pierde un grado de libertad (de ahí el nombre “grados de libertad”).

La demostración se basa en probar que

$$\chi^2 = \chi_{min}^2 + (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})$$

El primer término tiene distribución  $\chi_n^2$  y el tercero  $\chi_k^2$  pues es  $(\hat{\boldsymbol{\theta}} - \mathbf{E}(\hat{\boldsymbol{\theta}}))^T \mathbf{V}^{-1} (\hat{\boldsymbol{\theta}} - \mathbf{E}(\hat{\boldsymbol{\theta}}))$ . Por lo tanto el segundo término tiene que ser  $\chi_{n-k}^2$ .

$$\begin{aligned} \chi^2 &= (\mathbf{y} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A}\boldsymbol{\theta}) \\ &= (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}} + \mathbf{A}\hat{\boldsymbol{\theta}} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}} + \mathbf{A}\hat{\boldsymbol{\theta}} - \mathbf{A}\boldsymbol{\theta}) \\ &= (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}}) + (\mathbf{A}\hat{\boldsymbol{\theta}} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{A}\hat{\boldsymbol{\theta}} - \mathbf{A}\boldsymbol{\theta}) + \\ &\quad + (\mathbf{y} - \mathbf{A}\hat{\boldsymbol{\theta}})^T \mathbf{V}^{-1} (\mathbf{A}\hat{\boldsymbol{\theta}} - \mathbf{A}\boldsymbol{\theta}) + (\mathbf{A}\hat{\boldsymbol{\theta}} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A}\boldsymbol{\theta}) \\ &= \chi_{min}^2 + (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \end{aligned}$$

Queda como ejercicio mostrar que los dos últimos términos (iguales pues uno es el traspuesto del otro) valen cero. Esto se obtiene reemplazando  $\hat{\boldsymbol{\theta}}$  por su expresión en términos de  $\mathbf{y}$ .