

Algunas propiedades de la matriz \mathbf{P} :

Lema:

- i) \mathbf{P} y $\mathbf{I} - \mathbf{P}$ son simétricas e idempotentes
- ii) $\text{rg}(\mathbf{P}) = \text{tr}(\mathbf{P}) = p$ y $\text{rg}(\mathbf{I} - \mathbf{P}) = \text{tr}(\mathbf{I} - \mathbf{P}) = n - p$
- iii) $(\mathbf{I} - \mathbf{P})\mathbf{X} = \mathbf{0}$

Proposición: Dados $1 \leq i, j \leq n$ tenemos que

- i) $0 \leq p_{ii} \leq 1$
- ii) $-\frac{1}{2} \leq p_{ij} \leq \frac{1}{2}$ si $i \neq j$

Como ya vimos $\text{Var}(\hat{y}_i) = \sigma^2 p_{ii}$, una consecuencia inmediata es que

$$\text{Var}(\hat{y}_i) \leq \text{Var}(y_i) = \sigma^2 .$$

Una propiedad interesante es que **P** es invariante por transformaciones lineales no singulares de la forma $\mathbf{X} \rightarrow \mathbf{XA}$, donde $\mathbf{A} \in \mathfrak{R}^{p \times p}$ y $\text{rg}(\mathbf{A}) = p$. Este tipo de transformaciones es útil, por ejemplo, si queremos realizar un cambio de unidades en las covariables.

Respecto a las propiedades de invariancia, podemos ver que si

$$\widehat{\boldsymbol{\beta}} = \widehat{\boldsymbol{\beta}}(\mathbf{X}, \mathbf{Y}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y},$$

para $\mathbf{A} \in \mathfrak{R}^{p \times p}$ no singular, $\lambda \in \mathfrak{R}$ y $\boldsymbol{\gamma} \in \mathfrak{R}^p$, entonces

$$\begin{aligned} \widehat{\boldsymbol{\beta}}(\mathbf{XA}, \mathbf{Y}) &= \mathbf{A}^{-1}\widehat{\boldsymbol{\beta}} && \text{Invariancia por transformaciones afines} \\ \widehat{\boldsymbol{\beta}}(\mathbf{X}, \lambda\mathbf{Y}) &= \lambda\widehat{\boldsymbol{\beta}} && \text{Invariancia por cambios de escala} \\ \widehat{\boldsymbol{\beta}}(\mathbf{X}, \mathbf{Y} + \mathbf{X}\boldsymbol{\gamma}) &= \widehat{\boldsymbol{\beta}} + \boldsymbol{\gamma} && \text{Invariancia por cambios de regresión} \end{aligned}$$

Estimación de σ^2

Las varianzas de los estimadores dependen del diseño y σ^2 , que es desconocida. Dado que $\sigma^2 = E(\epsilon^2)$, parece natural estimarla mediante el promedio de los cuadrados de los residuos. El vector de residuos es

$$\begin{aligned}\mathbf{r} &= \mathbf{Y} - \widehat{\mathbf{Y}} \\ &= \mathbf{Y} - \mathbf{P}\mathbf{Y},\end{aligned}$$

Bajo el modelo Ω , tenemos que

$$s^2 = \frac{\|\mathbf{Y} - \widehat{\mathbf{Y}}\|^2}{n - p} = \frac{\|\mathbf{Y} - \mathbf{P}\mathbf{Y}\|^2}{n - p}$$

es un estimador insesgado de σ^2 .

Lema Auxiliar: Sea \mathbf{x} un vector aleatorio n -dimensional y sea $\mathbf{A} \in \mathfrak{R}^{n \times n}$ una matriz simétrica. Si $E(\mathbf{x}) = \boldsymbol{\mu}$ y su matriz de covarianza es $\Sigma_{\mathbf{x}}$ entonces

$$E(\mathbf{x}'\mathbf{A}\mathbf{x}) = \text{tr}(\mathbf{A}\Sigma) + \boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu}$$

Respecto del diseño

- **Covariables aleatorias**

Si las covariables son aleatorias suponemos que tenemos los vectores (\mathbf{x}_i, y_i) i.i.d. que satisfacen el modelo

$$y_i = \mathbf{x}_i \boldsymbol{\beta} + \epsilon_i$$

donde los ϵ_j son i.i.d., con $E(\epsilon_i) = 0$ y $Var(\epsilon_i) = \sigma^2$ e independientes de $\mathbf{x}_j \sim F$.

El análogo de suponer que \mathbf{X} tiene **rango completo** es asumir que la distribución de \mathbf{x} no está concentrada en ningún hiperplano, es decir

$$P(\mathbf{a}'\mathbf{x} = 0) < 1 \quad \forall \mathbf{a} \neq \mathbf{0}$$

Esta condición se cumple, por ejemplo, si \mathbf{x} tiene densidad.

En este caso, $\widehat{\boldsymbol{\beta}}$ está bien definido y las fórmulas que vimos para esperanza y varianza de $\widehat{\boldsymbol{\beta}}$ son válidas condicionalmente:

$$E(\widehat{\boldsymbol{\beta}} | \mathbf{X} = \mathbf{x}) = \boldsymbol{\beta} \quad \Sigma_{\widehat{\boldsymbol{\beta}} | \mathbf{x} = \mathbf{x}} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

Se puede ver que si $\mathbf{V}_x = E(\mathbf{x}\mathbf{x}')$ existe, entonces para n grande la distribución aproximada de $\hat{\boldsymbol{\beta}}$ será

$$N_p \left(\boldsymbol{\beta}, \frac{\sigma^2 \mathbf{V}_x^{-1}}{n} \right)$$

Cuando el modelo tiene intercept, podemos escribirlo como:

$$y_i = \beta_0 + \mathbf{x}'_i \boldsymbol{\beta}_1 + \epsilon_i$$

donde β_0 es la intercept y $\boldsymbol{\beta}_1$ es el vector de pendientes. En este caso resulta

$$\sigma^2 \mathbf{V}_x^{-1} = \sigma^2 \begin{pmatrix} 1 + \boldsymbol{\mu}'_x \boldsymbol{\Sigma}_x^{-1} \boldsymbol{\mu}_x & -\boldsymbol{\mu}'_x \boldsymbol{\Sigma}_x^{-1} \\ -\boldsymbol{\Sigma}_x^{-1} \boldsymbol{\mu}_x & \boldsymbol{\Sigma}_x^{-1} \end{pmatrix}$$

con $\boldsymbol{\mu}_x = E(\mathbf{x})$ y $\boldsymbol{\Sigma}_x$ matriz de covarianza de \mathbf{x} .

- **Estructura Ortogonal en la matriz de Diseño**

Supongamos que podemos dividir a la matriz \mathbf{X} en k conjuntos de columnas ortogonales: $\mathbf{X}_1, \dots, \mathbf{X}_k$, de manera que

$$\mathbf{X} = [\mathbf{X}_1 \dots \mathbf{X}_k]$$

La correspondiente división en los parámetros daría

$$\boldsymbol{\beta} = (\boldsymbol{\beta}_1, \dots, \boldsymbol{\beta}_k)'$$

Luego podemos escribir:

$$E(\mathbf{Y}) = \mathbf{X}_1\boldsymbol{\beta}_1 + \dots + \mathbf{X}_k\boldsymbol{\beta}_k$$

Como las columnas de \mathbf{X}_i son ortogonales a las de \mathbf{X}_j si $i \neq j$, tenemos que $\mathbf{X}_i'\mathbf{X}_j = 0$, luego

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \begin{pmatrix} \mathbf{X}'_1\mathbf{X}_1 & 0 & \dots & 0 \\ 0 & \mathbf{X}'_2\mathbf{X}_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \mathbf{X}'_k\mathbf{X}_k \end{pmatrix}^{-1} \begin{pmatrix} \mathbf{X}'_1\mathbf{Y} \\ \mathbf{X}'_2\mathbf{Y} \\ \dots \\ \mathbf{X}'_k\mathbf{Y} \end{pmatrix}$$

entonces

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \begin{pmatrix} (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{Y} \\ (\mathbf{X}'_2\mathbf{X}_2)^{-1}\mathbf{X}'_2\mathbf{Y} \\ \dots \\ (\mathbf{X}'_k\mathbf{X}_k)^{-1}\mathbf{X}'_k\mathbf{Y} \end{pmatrix} = \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \dots \\ \hat{\beta}_k \end{pmatrix}$$

en consecuencia el estimador de β_j no cambiará si alguno de los otros β_j se iguala a 0, es decir si se remueve del modelo.

¿Cómo resulta la suma de cuadrados?

$$\mathbf{Y}'\mathbf{Y} - \widehat{\mathbf{Y}}'\widehat{\mathbf{Y}} = \mathbf{Y}'\mathbf{Y} - \widehat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y} = \mathbf{Y}'\mathbf{Y} - \sum_{j=1}^k \widehat{\boldsymbol{\beta}}_j'\mathbf{X}_j'\mathbf{Y}$$

Por lo tanto si en el modelo ponemos algún $\boldsymbol{\beta}_i = 0$, el único cambio en la suma de cuadrados es que el término de $\widehat{\boldsymbol{\beta}}_i'\mathbf{X}_i'\mathbf{Y}$ no aparece:

$$\mathbf{Y}'\mathbf{Y} - \sum_{\substack{j=1 \\ j \neq i}}^k \widehat{\boldsymbol{\beta}}_j'\mathbf{X}_j'\mathbf{Y}$$

En el caso más sencillo, cada \mathbf{X}_i consta de una única columna y resulta:

$$\widehat{\boldsymbol{\beta}}_i = \frac{\mathbf{X}_i'\mathbf{Y}}{\mathbf{X}_i'\mathbf{X}_i}$$

y la suma de cuadrados queda

$$\mathbf{Y}'\mathbf{Y} - \sum_{j=1}^k \widehat{\boldsymbol{\beta}}_j'\mathbf{X}_j'\mathbf{Y} = \mathbf{Y}'\mathbf{Y} - \sum_{j=1}^k \widehat{\boldsymbol{\beta}}_j^2 \mathbf{X}_j'\mathbf{X}_j$$

Teorema de Gauss–Markov

En muchas aplicaciones estamos más interesados en estimar funciones lineales de $\boldsymbol{\beta}$ que en estimar $\boldsymbol{\beta}$ en sí mismo.

Estas funciones incluyen el valor esperado de y en una futura observación \mathbf{x}_0 , por ejemplo.

Si bien puede haber muchos estimadores de una función lineal $\mathbf{c}'\boldsymbol{\beta}$ o $\mathbf{C}\boldsymbol{\beta}$, estudiaremos los estimadores lineales, es decir funciones lineales de las observaciones y_1, \dots, y_n .

Primero veremos cuando una función paramétrica es **estimable**.

Definición: Una **función paramétrica** ψ se dice que es una **función lineal** de los parámetros $\{\beta_1, \dots, \beta_p\}$ si existen $\{c_1, \dots, c_p\}$ constantes conocidas tal que

$$\psi = \mathbf{c}'\boldsymbol{\beta} = \sum_{j=1}^p c_j \beta_j$$

donde $\mathbf{c} = (c_1, \dots, c_p)'$.

Definición: Decimos que una función paramétrica $\psi = \mathbf{c}'\boldsymbol{\beta}$ es **estimable** si tiene un estimador lineal (en \mathbf{Y}) insesgado, es decir si existe $\mathbf{a} \in \mathfrak{R}^n$ tal que

$$E(\mathbf{a}'\mathbf{Y}) = \psi = \mathbf{c}'\boldsymbol{\beta} \quad \forall \boldsymbol{\beta} \in \mathfrak{R}^p$$

¿Hay funciones que no son estimables?

Veamos un ejemplo de una función paramétrica no estimable.

Supongamos que queremos comparar la respuesta media de dos tratamientos y un control y que para ello observamos

$$\begin{array}{llll} \text{T1:} & y_{11}, y_{12}, \dots, y_{1k} & y_{1j} & \sim N(\beta_1, \sigma^2) \\ \text{T2:} & y_{21}, y_{22}, \dots, y_{2k} & y_{2j} & \sim N(\beta_2, \sigma^2) \\ \text{Co:} & y_{31}, y_{32}, \dots, y_{3k} & y_{3j} & \sim N(\beta_3, \sigma^2) \end{array}$$

Suponemos igual cantidad de observaciones por tratamiento para simplificar la notación.

Podemos escribir esto como

$$y_{ij} = \beta_i + \epsilon_{ij}$$

Podríamos escribir esto como un modelo lineal:

$$\mathbf{Y} = \begin{pmatrix} y_{11} \\ y_{12} \\ \dots \\ y_{1k} \\ y_{21} \\ y_{22} \\ \dots \\ y_{2k} \\ y_{31} \\ y_{32} \\ \dots \\ y_{3k} \end{pmatrix}; \mathbf{X} = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ \cdot & \cdot & \cdot \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \\ \cdot & \cdot & \cdot \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \\ \cdot & \cdot & \cdot \\ 0 & 0 & 1 \end{pmatrix}; \boldsymbol{\beta} = \begin{pmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix}$$

Por ejemplo, T1, T2 y el control podrían ser distintas dosis de una droga de manera que T1 es menor que la dosis del control y T2 mayor que la dosis

control. Tendría sentido preguntarse si

$$\beta_3 = \frac{\beta_1 + \beta_2}{2}$$

lo que implicaría cierta linealidad en el efecto medio. En ese caso nos interesaría saber si

$$\left(-\frac{1}{2}, -\frac{1}{2}, 1 \right) \begin{pmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix} = 0$$

Otra manera de escribir el modelo sería

$$y_{ij} = \mu + \alpha_i + \epsilon_{ij}$$

donde:

μ es el efecto general

α_i es el efecto del tratamiento i

En ese caso tendríamos

$$\mathbf{Y} = \begin{pmatrix} y_{11} \\ y_{12} \\ \dots \\ y_{1k} \\ y_{21} \\ y_{22} \\ \dots \\ y_{2k} \\ y_{31} \\ y_{32} \\ \dots \\ y_{3k} \end{pmatrix}; \mathbf{X} = \begin{pmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ \cdot & \cdot & \cdot & \cdot \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ \cdot & \cdot & \cdot & \cdot \\ 1 & 0 & 0 & 1 \end{pmatrix}; \boldsymbol{\beta} = \begin{pmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \end{pmatrix}$$

¿Son todas las funciones estimables en este modelo?

Consideremos

$$\alpha_1 = (0, 1, 0, 0) \begin{pmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \end{pmatrix}$$

Veremos que α_1 no es estimable.

Veamos el siguiente resultado que caracteriza las funciones paramétricas estimables.

Teorema: La función paramétrica $\psi = \mathbf{c}'\boldsymbol{\beta}$ es estimable si y sólo si \mathbf{c} es una combinación lineal de las filas de \mathbf{X} , o sea si existe $\mathbf{a} \in \mathfrak{R}^n$ tal que

$$\mathbf{c}' = \mathbf{a}'\mathbf{X}$$

Lema: Supongamos que vale el modelo Ω . Sean $\psi = \mathbf{c}'\boldsymbol{\beta}$ una función estimable y \mathcal{V}_r el espacio generado por las columnas de \mathbf{X} ($r = \text{rg}(\mathbf{X}) \leq p$). Luego, existe un único estimador lineal insesgado de ψ , digamos $\mathbf{a}^*\mathbf{Y}$ con $\mathbf{a}^* \in \mathcal{V}_r$. Más aún, si $\mathbf{a}'\mathbf{Y}$ es un estimador insesgado de ψ , \mathbf{a}^* es la proyección ortogonal de \mathbf{a} sobre \mathcal{V}_r .

Teorema de Gauss–Markov:

Supongamos que vale el modelo $\Omega : E(\mathbf{Y}) = \mathbf{X}\boldsymbol{\beta} \quad \Sigma\mathbf{Y} = \sigma^2\mathbf{I}$. Toda función estimable $\psi = \mathbf{c}'\boldsymbol{\beta}$ tiene un único estimador $\widehat{\psi}$ lineal insesgado de mínima varianza (BLUE). Este estimador $\widehat{\psi}$ se puede obtener reemplazando a $\boldsymbol{\beta}$ en $\mathbf{c}'\boldsymbol{\beta}$ por $\widehat{\boldsymbol{\beta}}$, el estimador de mínimos cuadrados.

Definición: Dada una función estimable ψ su único estimador lineal insesgado de mínima varianza $\widehat{\psi}$, cuya existencia y cálculo están dados por el Teorema de Gauss–Markov, es el estimador de mínimos cuadrados de ψ .

Tenemos el siguiente resultado:

Corolario: Si $\{\psi_1, \dots, \psi_q\}$ son q funciones estimables toda combinación lineal $\Psi = \sum_{i=1}^q h_i \psi_i$ es estimable y su estimador de mínimos cuadrados está dado por $\sum_{i=1}^q \hat{h}_i \psi_i$.