

Ejercicio 5

$$2) X_1, \dots, X_n \text{ MAS de } X \quad X \sim P(\lambda) \quad P_X(k) = \begin{cases} \frac{e^{-\lambda} \lambda^k}{k!} & \text{si } k \geq 0 \\ 0 & \text{si no} \end{cases}$$

buscamos el estimador por máxima verosimilitud de λ

• función de verosimilitud

$$\begin{aligned} L(\lambda, x_1, \dots, x_n) &= P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) \\ &= \prod_{i=1}^n P(X_i = x_i) \\ &= \prod_{i=1}^n \frac{e^{-\lambda} \lambda^{x_i}}{x_i!} \end{aligned}$$

• tomamos el logaritmo de la función de verosimilitud

$$\begin{aligned} h(\lambda, x_1, \dots, x_n) &= \log L(\lambda) \\ &= \log \left(\prod_{i=1}^n \frac{e^{-\lambda} \lambda^{x_i}}{x_i!} \right) \\ &= \sum_{i=1}^n \log \left(\frac{e^{-\lambda} \lambda^{x_i}}{x_i!} \right) \\ &= \sum_{i=1}^n (\log(e^{-\lambda}) + \log(\lambda^{x_i}) - \log(x_i!)) \\ &= \sum_{i=1}^n (-\lambda + x_i \log(\lambda) - \log(x_i!)) \\ &= \sum_{i=1}^n -\lambda + \sum_{i=1}^n x_i \log(\lambda) - \sum_{i=1}^n \log(x_i!) \\ &= -\lambda n + \log(\lambda) \sum_{i=1}^n x_i - \sum_{i=1}^n \log(x_i!) \end{aligned}$$

• el estimador por máxima verosimilitud de λ es

$$\hat{\lambda}_n = \operatorname{argmax} h(\lambda)$$

$$h'(\lambda) = -n + \frac{1}{\lambda} \sum_{i=1}^n x_i$$

$$h'(\lambda) = 0 \Leftrightarrow -n + \frac{1}{\lambda} \sum_{i=1}^n x_i = 0$$

$$\Leftrightarrow \frac{1}{\lambda} \sum_{i=1}^n x_i = n$$

$$\Leftrightarrow \lambda = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\boxed{\hat{\lambda}_n = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}_n}$$

faltaría ver que $h''(\frac{1}{n} \sum_{i=1}^n x_i) < 0$

$$h''(\lambda) = -\frac{1}{\lambda^2} \sum_{i=1}^n x_i \checkmark$$



④ x_1, \dots, x_n MAS de X donde $X \sim \mathcal{N}(\mu, \sigma^2)$

buscamos estimador por máxima verosimilitud de μ y de σ^2

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

• función de verosimilitud

$$\begin{aligned} \mathcal{L}(\mu, \sigma^2, x_1, \dots, x_n) &= \prod_{i=1}^n f_X(x_i) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x_i-\mu)^2} \\ &= \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2} \\ &= (2\pi\sigma^2)^{-n/2} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2} \end{aligned}$$

• tomamos el logaritmo de la función de verosimilitud

$$\begin{aligned} h(\mu, \sigma^2) &= \log(\mathcal{L}(\mu, \sigma^2)) \\ &= \log((2\pi\sigma^2)^{-n/2} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2}) \\ &= \log((2\pi\sigma^2)^{-n/2}) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2 \end{aligned}$$

$n, 1, x_1, \dots, x_n, 1, 2$

$$= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

- estimador de μ por máxima verosimilitud

$$\frac{\partial h(\mu, \sigma^2)}{\partial \mu} = \frac{1}{2\sigma^2} \sum_{i=1}^n 2(x_i - \mu) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)$$

$$\frac{\partial h(\mu, \sigma^2)}{\partial \mu} = 0 \Leftrightarrow \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0$$

$$\Leftrightarrow \sum_{i=1}^n (x_i - \mu) = 0$$

$$\Leftrightarrow \sum_{i=1}^n x_i - \sum_{i=1}^n \mu = 0$$

$$\Leftrightarrow \sum_{i=1}^n x_i - n\mu = 0$$

$$\Leftrightarrow \mu = \frac{1}{n} \sum_{i=1}^n x_i$$

entonces $\hat{\mu}_n = \frac{1}{n} \sum_{i=1}^n x_i = \bar{X}_n$

- estimador de σ^2 :

$$\frac{\partial h(\mu, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2} \frac{1}{(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$= \frac{1}{2\sigma^2} \left(-n + \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right)$$

$$\frac{\partial h(\mu, \sigma^2)}{\partial \sigma^2} = 0 \Leftrightarrow -n + \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 = 0$$

$$\Leftrightarrow \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 = n$$

$$\Leftrightarrow \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$$

$$\hat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X}_n)^2$$


$$\Leftrightarrow \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu}_n)^2$$

$$\Rightarrow \boxed{\hat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu}_n)^2}$$

⑤ X_1, \dots, X_n MAS de X donde $X \sim U[a, b]$

buscamos estimador por máxima verosimilitud de a y b

$$f_X(x) = \begin{cases} \frac{1}{b-a} & \text{si } x \in [a, b] \\ 0 & \text{si no} \end{cases}$$




todas las observaciones x_1, \dots, x_n tiene que estar en $[a, b]$

función de verosimilitud:

$$L(a, b, x_1, \dots, x_n) = \prod_{i=1}^n f_X(x_i) = \prod_{i=1}^n \frac{1}{b-a} = \left(\frac{1}{b-a}\right)^n$$

cuanto más chico sea $b-a$ más grande es $L(a, b)$




$$\hat{a}_n = \min \{x_1, \dots, x_n\}$$

$$\hat{b}_n = \max \{x_1, \dots, x_n\}$$


Sesgo de un estimador

$\hat{\theta}_n$ estimador de θ

$$\text{sesgo}(\hat{\theta}_n) = E(\hat{\theta}_n) - \theta$$



decimos que $\hat{\theta}_n$ es insesgado si $\text{sesgo}(\hat{\theta}_n) = 0$ o equivalentemente si $E(\hat{\theta}_n) = \theta$



Ejercicio 7

Se considera una muestra X_1, X_2, \dots, X_n iid con media $E(X) = \mu$ y varianza $\text{Var}(X) = \sigma^2$. Se considera el estimador $\hat{\mu} = \sum_{i=1}^n a_i X_i$ (una combinación lineal de las observaciones).

1. Hallar la relación que tienen que cumplir los coeficientes a_i para que $\hat{\mu}$ sea un estimador insesgado de la media μ .
2. Entre todos los estimadores lineales e insesgados de la media μ hallar el de varianza mínima.
Sugerencia: usar la desigualdad de Cauchy-Schwarz para vectores en \mathbb{R}^n .

① queremos que se verifique: $E(\hat{\mu}) = \mu$

$$E(\hat{\mu}) = E\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i \underbrace{E(X_i)}_{\mu} = \mu \sum_{i=1}^n a_i$$

para que $\hat{\mu}$ sea insesgado se tiene que verificar $\boxed{\sum_{i=1}^n a_i = 1}$

$$\begin{aligned} E(a_1 X_1 + a_2 X_2 + \dots + a_n X_n) &= E(a_1 X_1) + E(a_2 X_2) + \dots + E(a_n X_n) \\ &= a_1 E(X_1) + a_2 E(X_2) + \dots + a_n E(X_n) \end{aligned}$$

② queremos minimizar $\text{Var}(\hat{\mu})$ bajo la condición $\sum_{i=1}^n a_i = 1$

$$\text{Var}(\hat{\mu}) = \text{Var}\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n \text{Var}(a_i X_i) = \sum_{i=1}^n a_i^2 \underbrace{\text{Var}(X_i)}_{\sigma^2} = \sigma^2 \sum_{i=1}^n a_i^2$$

los X_i son
independientes

queremos minimizar $\sum_{i=1}^n a_i^2$ bajo la condición $\sum_{i=1}^n a_i = 1$

Cauchy-Schwarz:

$u, v \in \mathbb{R}^n$ entonces $(\langle u, v \rangle)^2 \leq \|u\|^2 \|v\|^2$

y se da el igual cuando u y v son colineales
 $u = \lambda v$

$$\left. \begin{array}{l} u = (a_1, \dots, a_n) \\ v = (b_1, \dots, b_n) \end{array} \right\} \Rightarrow \left(\sum_{i=1}^n a_i b_i \right)^2 \leq \left(\sum_{i=1}^n a_i^2 \right) \left(\sum_{i=1}^n b_i^2 \right)$$

tomamos $u = (a_1, \dots, a_n)$
 $v = (1, \dots, 1)$

entonces:

$$\underbrace{\left(\sum_{i=1}^n a_i \right)^2}_{1} \leq \left(\sum_{i=1}^n a_i^2 \right) \cdot n$$

$$\frac{1}{n} \leq \sum_{i=1}^n a_i^2$$

se da el igual cuando u y v son colineales

o sea cuando $u = \lambda v = (\lambda, \dots, \lambda)$

\Rightarrow se da el igual cuando $a_i = a_j$ para todo $i, j = 1, \dots, n$

$$\left. \begin{array}{l} \text{todos los } a_i \text{ son iguales} \\ \sum_{i=1}^n a_i = 1 \end{array} \right\} \Rightarrow a_i = \frac{1}{n} \text{ para todo } i$$

el estimador lineal de μ insesgado con varianza mínima es $\hat{\mu} = \sum_{i=1}^n \frac{1}{n} x_i$
 $\hat{\mu} = \bar{X}_n$

Ejercicio 6

Sean $(X_n)_{n \in \mathbb{N}}$ iid tales que $E(X_1) = \mu$ y $\text{Var}(X_1) = \sigma^2 < \infty$ ($\sigma > 0$). Mostrar que \bar{X}_n es insesgado como estimador de μ , que σ_n^2 no es insesgado como estimador de σ^2 y que s_n^2 es insesgado para σ^2 .

• σ_n^2 no es un estimador insesgado de σ^2

$$\sigma_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X}_n)^2$$

$$E(\sigma_n^2) = E\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X}_n)^2\right)$$

$$= E\left(\frac{1}{n} \sum_{i=1}^n (x_i^2 - 2\bar{X}_n x_i + \bar{X}_n^2)\right)$$

$$= E\left(\frac{1}{n} \left(\sum_{i=1}^n x_i^2 - 2\bar{X}_n \sum_{i=1}^n x_i + \sum_{i=1}^n \bar{X}_n^2 \right)\right)$$

$$= E\left(\frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{X}_n \frac{1}{n} \sum_{i=1}^n x_i + \frac{1}{n} \sum_{i=1}^n \bar{X}_n^2\right)$$

$$= E\left(\frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{X}_n^2 + \bar{X}_n^2\right)$$

$$= E\left(\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}_n^2\right)$$

$$= E\left(\frac{1}{n} \sum_{i=1}^n x_i^2\right) - E(\bar{X}_n^2)$$

$$E(X^2) = \mu \quad = \frac{1}{n} \sum_{i=1}^n \frac{E(X_i^2)}{E(X^2)} - E(\bar{X}_n^2)$$

$$E(X^2)$$

$$= \frac{1}{n} n E(X^2) - E\left(\frac{(X_1 + \dots + X_n)^2}{n^2}\right)$$

$$= E(X^2) - \frac{1}{n^2} E((X_1 + \dots + X_n)^2)$$

$$= E(X^2) - \frac{1}{n^2} E\left(\sum_{i=1}^n x_i^2 + \sum_{i \neq j} x_i x_j\right)$$

$$\begin{aligned}
&= E(X^2) - \frac{1}{n^2} E\left(\sum_{i=1}^n X_i^2 + \sum_{i \neq j} X_i X_j\right) \\
&= E(X^2) - \frac{1}{n^2} \left(E\left(\sum_{i=1}^n X_i^2\right) + E\left(\sum_{i \neq j} X_i X_j\right) \right) \\
&= E(X^2) - \frac{1}{n^2} \left(\sum_{i=1}^n E(X_i^2) + \sum_{i \neq j} E(X_i X_j) \right) \\
&= E(X^2) - \frac{1}{n^2} \left(n E(X^2) + \sum_{i \neq j} \underbrace{E(X_i) E(X_j)}_{= E(X)^2} \right) \\
&= E(X^2) - \frac{1}{n^2} (n E(X^2) + n(n-1) E(X)^2) \\
&= E(X^2) - \frac{1}{n} E(X^2) - \frac{n-1}{n} E(X)^2 \\
&= \frac{n-1}{n} E(X^2) - \frac{n-1}{n} E(X)^2 \\
&= \frac{n-1}{n} \text{Var}(X) \\
&= \frac{n-1}{n} \sigma^2
\end{aligned}$$

$$E(\sigma_n^2) = \sigma^2 - \underbrace{\frac{1}{n} \sigma^2}_{\text{sesgo de } \sigma_n^2}$$

$$\text{sesgo}(\sigma_n^2) = E(\sigma_n^2) - \sigma^2 = -\frac{1}{n} \sigma^2$$