

**XIII EDICIÓN PREMIOS JORGE JUAN
ESTADÍSTICA**

Sea X una variable aleatoria con función de densidad

$$f_{\theta}(x) = \frac{1}{2} \exp\{-|x - \theta|\}, \quad x \in \mathbb{R}, \theta \in \mathbb{R}.$$

Sea (X_1, X_2, \dots, X_n) una muestra aleatoria simple de X .

- (a) Obtener un estadístico suficiente para θ .
- (b) Obtener un estimador por el método de los momentos de θ . ¿Es único?
- (c) Obtener un estimador de máxima verosimilitud para θ . ¿Es único?

NOTAS:

Sea X una variable aleatoria, $\theta \in \Theta \subset \mathbb{R}^k$, $k \geq 1$, un parámetro desconocido respecto del cuál depende la distribución teórica poblacional, (X_1, X_2, \dots, X_n) una muestra aleatoria simple de X .

1. Un estadístico $S = S(X_1, \dots, X_n)$ es *suficiente* para θ si y sólo si la función de densidad o de probabilidad conjunta de la muestra aleatoria simple puede factorizarse de la siguiente forma:

$$f_{\theta}(x_1, \dots, x_n) = h(x_1, \dots, x_n) \cdot k(\theta, S(x_1, \dots, x_n)), \quad \forall (x_1, \dots, x_n) \in \mathbb{R}^n.$$

2. Un *estimador por el método de los momentos* para θ , $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ se obtiene reemplazando r momentos poblacionales $\mu_j = E(X^j)$, $j = 1, \dots, r$, $r \geq k$, por los correspondientes

momentos muestrales, $m_j = \frac{1}{n} \sum_{i=1}^n X_i^j$.

3. Un *estimador de máxima verosimilitud* $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ para θ es aquél que, para cada muestra observada de la población (x_1, x_2, \dots, x_n) , $\hat{\theta}(x_1, \dots, x_n)$ maximiza la función de verosimilitud de la muestra. Para una distribución poblacional continua, *la función de verosimilitud* de la muestra observada es la función de densidad de la muestra vista como función del parámetro.

SOLUCIÓN

1. La función de densidad conjunta de la muestra aleatoria simple:

$$f_{\theta}(x_1, \dots, x_n) = \frac{1}{2^n} \exp \left\{ -\sum_{i=1}^n |x_i - \theta| \right\}, \quad (x_1, \dots, x_n) \in \mathbb{R}^n.$$

Si tomamos:

$$h(x_1, \dots, x_n) = \frac{1}{2^n}, \quad \forall (x_1, \dots, x_n) \in \mathbb{R}^n,$$

$$k(\theta, S(x_1, \dots, x_n)) = \exp \left\{ -\sum_{i=1}^n |x_i - \theta| \right\},$$

$$S(x_1, \dots, x_n) = (x_1, \dots, x_n),$$

de acuerdo con el teorema de Factorización, $S(X_1, \dots, X_n) = (X_1, \dots, X_n)$, es suficiente para θ , y no existe otro de menor dimensión.

2. Calculemos μ_1 :

$$\begin{aligned} \mu_1 = E(X) &= \frac{1}{2} \int_{-\infty}^{\infty} x e^{-|x-\theta|} dx = \frac{1}{2} \left\{ \int_{-\infty}^{\theta} x e^{-\theta+x} dx + \int_{\theta}^{\infty} x e^{-x+\theta} dx \right\} = \\ &= \frac{1}{2} \left\{ \int_0^{\infty} (\theta - y) e^{-y} dy + \int_0^{\infty} (y + \theta) e^{-y} dy \right\} = \\ &= \frac{1}{2} \left\{ \int_0^{\infty} \theta e^{-y} dy - \int_0^{\infty} y e^{-y} dy + \int_0^{\infty} y e^{-y} dy + \int_0^{\infty} \theta e^{-y} dy \right\} = \theta \int_0^{\infty} e^{-y} dy = \theta. \end{aligned}$$

(*) En la primera integral, hemos hecho el cambio $y = -x + \theta$, y en la segunda integral, $y = -\theta + x$.

Obtenemos $\mu_1 = \theta \Rightarrow \hat{\theta} = m_1 = \bar{X}$ es un estimador por el método de los momentos de θ .

En cuanto a su unicidad, podemos calcular μ_2 :

$$\begin{aligned} \mu_2 = E(X^2) &= \frac{1}{2} \int_{-\infty}^{\infty} x^2 e^{-|x-\theta|} dx = \frac{1}{2} \left\{ \int_{-\infty}^{\theta} x^2 e^{-\theta+x} dx + \int_{\theta}^{\infty} x^2 e^{-x+\theta} dx \right\} = \\ &= \frac{1}{2} \left\{ \left[x^2 e^{-\theta+x} \right]_{-\infty}^{\theta} - \int_{-\infty}^{\theta} 2x e^{-\theta+x} dx + \left[-x^2 e^{-x+\theta} \right]_{\theta}^{\infty} + \int_{\theta}^{\infty} 2x e^{-x+\theta} dx \right\} = \\ &= \frac{1}{2} \left\{ \theta^2 - 2 \int_0^{\infty} (\theta - y) e^{-y} dy + \theta^2 + 2 \int_0^{\infty} (\theta + y) e^{-y} dy \right\} = \\ &= \theta^2 + 2 \int_0^{\infty} y e^{-y} dy = \theta^2 + 2. \end{aligned}$$

(*) Resolviendo por partes.

(**) En la primera integral, hemos hecho el cambio $y = -x + \theta$, y en la segunda integral, $y = -\theta + x$.

Obtenemos $\mu_2 = \theta^2 + 2 \Rightarrow \theta = \pm\sqrt{\mu_2 - 2}$. Obtenemos dos estimadores más por el método de los

momentos: $\tilde{\theta} = \sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2 - 2}$ y $\hat{\theta} = -\sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2 - 2}$. Por lo tanto no es único.

3. La función de verosimilitud del parámetro θ para cada muestra observada (x_1, \dots, x_n) es:

$$L(x_1, \dots, x_n, \theta) = \frac{1}{2^n} \exp\left\{-\sum_{i=1}^n |x_i - \theta|\right\}, \quad \theta \in \mathbb{R}.$$

Esta función no es derivable respecto de θ , pero observamos que

$$\max_{\theta \in \mathbb{R}} L(x_1, \dots, x_n, \theta) \Leftrightarrow \min_{\theta \in \mathbb{R}} \sum_{i=1}^n |x_i - \theta|$$

Vamos a llamar $H(\theta) := \sum_{i=1}^n |x_i - \theta| = \sum_{i=1}^n |x_{(i)} - \theta|$, expresada en términos de la muestra ordenada.

Evidentemente, $H(\theta)$ dependerá de la posición de θ respecto de la muestra ordenada.

Vamos a distinguir según n sea par o impar, pues ello afectará al resultado final.

CASO 1.- Si $n = 2k$, $k \in \mathbb{N}$.

- Si $\theta \leq x_{(1)}$, $H(\theta) = \sum_{i=1}^{2k} (x_{(i)} - \theta) = \sum_{i=1}^{2k} x_{(i)} - (2k)\theta$. Se trata de una recta de pendiente negativa igual a $-2k$.
- Si $x_{(1)} < \theta \leq x_{(2)}$, $H(\theta) = (\theta - x_{(1)}) + \sum_{i=2}^{2k} (x_{(i)} - \theta) = \sum_{i=2}^{2k} x_{(i)} - x_{(1)} - 2(k-1)\theta$. Obtenemos de nuevo una recta de pendiente negativa igual a $-2(k-1) > -2k$.

Siguiendo este esquema, comprobamos que, siempre que $\theta \leq x_{(k)}$, $H(\theta)$ está formada por segmentos de rectas de pendiente negativa, cuyo valor absoluto, que es un número par, va disminuyendo. Claramente, $H(\theta)$ es decreciente para $\theta \leq x_{(k)}$.

- Si $x_{(k)} < \theta \leq x_{(k+1)}$, $H(\theta) = \sum_{i=1}^k (\theta - x_{(i)}) + \sum_{i=k+1}^{2k} (x_{(i)} - \theta) = \sum_{i=k+1}^{2k} x_{(i)} - \sum_{i=1}^k x_{(i)}$, función constante en θ .

- Si $x_{(k+1)} < \theta \leq x_{(k+2)}$, $H(\theta) = \sum_{i=1}^{k+1} (\theta - x_{(i)}) + \sum_{i=k+2}^{2k} (x_{(i)} - \theta) = \sum_{i=k+2}^{2k} x_{(i)} - \sum_{i=1}^{k+1} x_{(i)} + 2\theta$. Obtenemos en este caso una recta de pendiente positiva igual a 2.

Siguiendo este esquema, comprobamos que, siempre que $x_{(k+1)} < \theta \leq x_{(2k)}$, $H(\theta)$ está formada por segmentos de rectas de pendiente positiva, cuyo valor (par) va aumentando.

- Si $\theta > x_{(2k)}$, $H(\theta) = \sum_{i=1}^{2k} (\theta - x_{(i)}) = (2k)\theta - \sum_{i=1}^{2k} x_{(i)}$. Se trata de una recta de pendiente positiva igual a $2k$.

Claramente, $H(\theta)$ es creciente para $\theta > x_{(k+1)}$.

La conclusión es que, dado que $H(\theta)$ es una función continua en toda la recta real, alcanza su valor mínimo en cualquier punto del segmento $[x_{(k)}, x_{(k+1)}]$. Así, el estimador de máxima verosimilitud de

θ no es único: $\hat{\theta}_\alpha = \alpha X_{(k)} + (1 - \alpha) X_{(k+1)}, \quad 0 \leq \alpha \leq 1$.

CASO 2.- Si $n = 2k+1$, $k \in \mathbb{N}$.

Procedemos de una forma análoga al CASO 1, comprobando que, siempre que $\theta \leq x_{(k+1)}$, $H(\theta)$ está formada por segmentos de rectas de pendiente negativa, cuyo valor absoluto, que es un número impar, va disminuyendo. Claramente, $H(\theta)$ es decreciente para $\theta \leq x_{(k+1)}$.

A continuación, comprobamos que, siempre que $x_{(k+1)} < \theta$, $H(\theta)$ está formada por segmentos de rectas de pendiente positiva, cuyo valor (impar) va aumentando. Claramente, $H(\theta)$ es creciente para $\theta > x_{(k+1)}$. La conclusión es que, dado que $H(\theta)$ es una función continua en toda la recta real, alcanza su valor mínimo en $x_{(k+1)}$. Así, el estimador de máxima verosimilitud de θ es único:

$\hat{\theta} = X_{(k+1)}$.