

**XIV EDICIÓN PREMIOS JORGE JUAN  
ESTADÍSTICA**

Supongamos  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  tiene una distribución conjunta dependiente de un parámetro unidimensional desconocido  $\theta$ , y sea  $f_\theta(\mathbf{x})$  su función de densidad conjunta. Consideremos una función real del parámetro  $\theta$ ,  $g(\theta)$ .

Sea  $T = T(\mathbf{X})$  un estimador insesgado para  $g(\theta)$  con  $V_\theta(T) < \infty$ .

(a) Sea  $\mathbf{U} = \{U: E_\theta(U) = 0, E_\theta(U^2) < \infty\}$  el conjunto de todos los estadísticos  $U = U(\mathbf{X})$  que son estimadores insesgados de 0 con varianza finita.

(a.1) Demostrar que cualquier estimador  $S = S(\mathbf{X})$  insesgado para  $g(\theta)$  tal que  $V_\theta(S) < \infty$ , puede ser expresado como  $S = T + U$ , para algún estadístico  $U \in \mathbf{U}$ .

(a.2) Demostrar que  $Cov_\theta(T, U) = 0$ , para todo  $U \in \mathbf{U}$ , si y sólo si,  $T$  es el estimador insesgado de mínima varianza para  $g(\theta)$ .

(Ayuda: para la parte “ $\leftarrow$ ”, considerar la familia de estimadores  $\{S_\alpha = T + \alpha U, \alpha \in R\}$ , y comparar su varianza con la de  $T$ ).

(b) Demostrar que

$$V_\theta(T) \geq \frac{[g(\theta + h) - g(\theta)]^2}{V_\theta(\varphi(\mathbf{X}, \theta))},$$

donde  $\varphi(\mathbf{x}, \theta) = \frac{f_{\theta+h}(\mathbf{x}) - f_\theta(\mathbf{x})}{f_\theta(\mathbf{x})}$ , siempre que  $\theta + h$  esté dentro del espacio paramétrico y

$f_\theta(\mathbf{x}) > 0$ .

**NOTA:**

Os puede resultar de utilidad en algún momento *la desigualdad de Cauchy-Schwarz*: Si  $X$  e  $Y$  son dos variables aleatorias con varianza finita, entonces  $E(XY)^2 \leq E(X^2)E(Y^2)$ .

## SOLUCION:

(a.1) Sea  $S = S(X)$ , tal que  $E_\theta(S) = g(\theta)$ ,  $V_\theta(S) < \infty$ .

Llamemos  $U := S - T$ .

Entonces  $E_\theta(U) = E_\theta(S - T) = 0$ .

Además,  $E_\theta(U^2) = E_\theta(S - T)^2 = E_\theta(S^2) + E_\theta(T^2) - 2E_\theta(ST)$ .

Ahora,  $E_\theta(S^2) < \infty$ ,  $E_\theta(T^2) < \infty$ , y por la desigualdad de Cauchy-Schwarz,  $E_\theta(ST) < \infty$ , por lo tanto  $E_\theta(U^2) < \infty$ , y  $U \in \mathbf{U}$ .

(a.2) “ $\rightarrow$ ” Veamos que para todo estimador  $S$  tal que  $E_\theta(S) = g(\theta)$ , se verifica que  $V_\theta(T) \leq V_\theta(S)$ , para todo  $\theta$ .

Si la varianza de  $S$  no es finita, no hay nada que demostrar.

Si  $V_\theta(S) < \infty$ , por el apartado (a.1), existe  $U \in \mathbf{U}$  tal que  $S = T + U$ , entonces

$$V_\theta(S) = V_\theta(T) + V_\theta(U) + 2Cov_\theta(T, U) \geq V_\theta(T),$$

pues, por hipótesis,  $Cov_\theta(T, U) = 0$ , y obviamente  $V_\theta(U) \geq 0$ .

“ $\leftarrow$ ” Sea  $U \in \mathbf{U}$ . Consideremos la familia de estimadores  $S_\alpha = T + \alpha U$ ,  $\alpha \in R$ . Entonces

$$E_\theta(S_\alpha) = E_\theta(T) + \alpha E_\theta(U) = g(\theta), \alpha \in R,$$

de manera que  $S_\alpha$  es insesgado para  $g(\theta)$ , para todo  $\alpha \in R$ , y al ser, por hipótesis,  $T$  el estimador insesgado de mínima varianza para  $g(\theta)$ , se cumplirá  $V_\theta(T) \leq V_\theta(S_\alpha)$ , para todo  $\alpha \in R$ .

Desarrollando, obtenemos

$$V_\theta(T) \leq V_\theta(T) + \alpha^2 V_\theta(U) + 2 \alpha Cov_\theta(T, U), \text{ para todo } \alpha \in R.$$

Así,  $\alpha^2 V_\theta(U) + 2 \alpha Cov_\theta(T, U) \geq 0$ , para todo  $\alpha \in R$ .

Como  $U$  no puede ser un estimador constante, necesariamente  $V_\theta(U) > 0$ , de manera que la función

$$h(\alpha) := \alpha^2 V_\theta(U) + 2 \alpha Cov_\theta(T, U), \alpha \in R$$

es una parábola convexa que pasa por el origen, con  $h(\alpha) \geq 0$ , para todo  $\alpha \in R$ . Así  $Cov_\theta(T, U) = 0$ .

(b) Veamos que  $[g(\theta + h) - g(\theta)]^2 \leq V_\theta(\varphi(\mathbf{X}, \theta))V_\theta(T)$ .

Si  $V_\theta(\varphi(\mathbf{X}, \theta)) = \infty$ , no hay nada que demostrar.

En otro caso, aplicando la desigualdad de Cauchy-Schwarz a las variables aleatorias  $\varphi(\mathbf{X}, \theta)$  y  $T - g(\theta)$ , obtenemos

$$E_\theta \left( \varphi(\mathbf{X}, \theta)(T - g(\theta)) \right)^2 \leq E_\theta(\varphi(\mathbf{X}, \theta)^2)E_\theta \left( (T - g(\theta))^2 \right).$$

Ahora,  $E_\theta \left( (T - g(\theta))^2 \right) = V_\theta(T)$ . Además

$$\begin{aligned} E_\theta(\varphi(\mathbf{X}, \theta)) &= \int \dots \int_{\mathbb{R}^n} \varphi(x_1, \dots, x_n, \theta) f_\theta(x_1, \dots, x_n) dx_1 \dots dx_n \\ &= \int \dots \int_{\mathbb{R}^n} \frac{f_{\theta+h}(x_1, \dots, x_n) - f_\theta(x_1, \dots, x_n)}{f_\theta(x_1, \dots, x_n)} f_\theta(x_1, \dots, x_n) dx_1 \dots dx_n \\ &= \int \dots \int_{\mathbb{R}^n} f_{\theta+h}(x_1, \dots, x_n) dx_1 \dots dx_n - \int \dots \int_{\mathbb{R}^n} f_\theta(x_1, \dots, x_n) dx_1 \dots dx_n = 0. \end{aligned}$$

Por lo tanto,  $E_\theta(\varphi(\mathbf{X}, \theta)^2) = V_\theta(\varphi(\mathbf{X}, \theta))$ .

Por otro lado,

$$\begin{aligned} E_\theta \left( \varphi(\mathbf{X}, \theta)(T - g(\theta)) \right) &= \int \dots \int_{\mathbb{R}^n} \varphi(x_1, \dots, x_n, \theta)(T(x_1, \dots, x_n) - g(\theta)) f_\theta(x_1, \dots, x_n) dx_1 \dots dx_n \\ &= \int \dots \int_{\mathbb{R}^n} f_{\theta+h}(x_1, \dots, x_n)T(x_1, \dots, x_n) dx_1 \dots dx_n - g(\theta) \int \dots \int_{\mathbb{R}^n} f_{\theta+h}(x_1, \dots, x_n) dx_1 \dots dx_n \\ &\quad - \int \dots \int_{\mathbb{R}^n} f_\theta(x_1, \dots, x_n)T(x_1, \dots, x_n) dx_1 \dots dx_n + g(\theta) \int \dots \int_{\mathbb{R}^n} f_\theta(x_1, \dots, x_n) dx_1 \dots dx_n \\ &= g(\theta + h) - g(\theta) - g(\theta) + g(\theta) = g(\theta + h) - g(\theta). \end{aligned}$$

Así,  $E_\theta \left( \varphi(\mathbf{X}, \theta)(T - g(\theta)) \right)^2 = [g(\theta + h) - g(\theta)]^2$ .