

Ya tenemos

- algunos estimadores “naturales”, junto con diversas propiedades de interés (sesgo, varianza, ECM);
- además de métodos generales de construcción de estimadores (momentos, máxima verosimilitud).

Nos disponemos ahora a analizar

- la cota de Cramér-Rao;
- y el comportamiento asintótico (para n , tamaño de la muestra, grande) de estimadores.

Derivadas de funciones de densidad/masa

Variable X con función de densidad/masa $f(x; \theta)$, con $x \in \text{sop}_\theta$ y $\theta \in \Theta$. Suponemos que Θ es un intervalo.

Muestra aleatoria (X_1, \dots, X_n) con función de densidad conjunta $f(\mathbf{x}; \theta)$ dada por

$$f(\mathbf{x}; \theta) = \prod_{j=1}^n f(x_j; \theta),$$

con $\mathbf{x} = (x_1, \dots, x_n) \in \text{sop}_\theta^n$ y $\theta \in \Theta$.

Interesa disponer de una expresión explícita de la derivada de $f(\mathbf{x}; \theta)$ con respecto a θ .

Usaremos la notación ∂_θ , en lugar de $\frac{\partial}{\partial \theta}$ o $\frac{d}{d \theta}$.

Derivamos el producto:

$$\partial_{\theta} \left(f(\mathbf{x}; \theta) \right) = \partial_{\theta} \left(\prod_{j=1}^n f(x_j; \theta) \right) = \sum_{j=1}^n \partial_{\theta} f(x_j; \theta) \frac{f(\mathbf{x}; \theta)}{f(x_j; \theta)},$$

es decir,

$$\frac{\partial_{\theta} f(\mathbf{x}; \theta)}{f(\mathbf{x}; \theta)} = \sum_{j=1}^n \frac{\partial_{\theta} f(x_j; \theta)}{f(x_j; \theta)}$$

o bien

$$\partial_{\theta} \ln(f(\mathbf{x}; \theta)) = \sum_{j=1}^n \partial_{\theta} \ln(f(x_j; \theta))$$

Información/número de información de una variable aleatoria

Llamamos **información de la variable** X a la variable aleatoria Y dada por

$$Y = \frac{\partial_\theta f(X; \theta)}{f(X; \theta)} = \partial_\theta \ln(f(X; \theta)).$$

Para cada $\theta \in \Theta$, la variable Y está definida por la expresión anterior en sop_θ ; fuera de sop_θ entendemos que $Y \equiv 0$.

El **número/cantidad de información de** $f(x; \theta)$ se define como la varianza de Y :

$$I_X(\theta) = \mathbf{V}_\theta(Y) = \mathbf{V}_\theta(\partial_\theta \ln(f(X; \theta))).$$

I_X es una función definida para $\theta \in \Theta$.

Ejemplo 1. Digamos que X es una variable $\text{EXP}(\lambda)$. El parámetro θ que se desea estimar es la media: $\theta = 1/\lambda$. La función de densidad es

$$f(x; \theta) = \frac{1}{\theta} e^{-x/\theta}, \quad \text{para } x > 0.$$

Obsérvese que $\mathbf{E}_\theta(X) = (1/\lambda) = \theta$ y que $\mathbf{V}_\theta(X) = (1/\lambda^2) = \theta^2$.

Como

$$\ln f(x; \theta) = -\ln(\theta) - \frac{x}{\theta} \implies \partial_\theta(\ln f(x; \theta)) = \frac{(x - \theta)}{\theta^2},$$

y, por tanto,

$$Y = \frac{X - \theta}{\theta^2},$$

de donde

$$I_X(\theta) = \mathbf{V}_\theta(Y) = \mathbf{E}_\theta(Y^2) = \frac{1}{\theta^4} \mathbf{V}_\theta(X) = \frac{1}{\theta^2}.$$

Ejemplo 2. Digamos que X es una variable $\text{POISS}(\lambda)$. El parámetro es $\theta = \lambda$. La función de masa es

$$f(k; \lambda) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad \text{para cada entero } k \geq 0.$$

Obsérvese que $\mathbf{E}_\lambda(X) = \lambda$ y que $\mathbf{V}_\lambda(X) = \lambda$.

Como

$$\ln f(k; \lambda) = -\lambda + k \ln(\lambda) - \ln(k!) \implies \partial_\lambda (\ln f(x; \lambda)) = -1 + \frac{k}{\lambda},$$

y, por tanto,

$$Y = \frac{X - \lambda}{\lambda},$$

de donde

$$I_X(\lambda) = \mathbf{V}_\lambda(Y) = \mathbf{E}_\lambda(Y^2) = \frac{1}{\lambda^2} \mathbf{V}_\lambda(X) = \frac{1}{\lambda}.$$

(No)-ejemplo 3. Digamos que X es una variable UNIF $[0, b]$. El parámetro es $\theta = b$. La función de densidad es

$$f(x; b) = \frac{1}{b} \quad \text{para } x \in [0, b].$$

Obsérvese que $\mathbf{E}_b(X) = b/2$ y que $\mathbf{V}_b(X) = b^2/12$.

Como

$$\ln f(x; b) = -\ln(b) \implies \partial_b(\ln f(x; b)) = -\frac{1}{b},$$

resulta que

$$Y = -\frac{1}{b},$$

Se trata de un caso “degenerado”: obsérvese que $\mathbf{E}_b(Y) = -1/b$, que $\mathbf{E}_b(Y^2) = 1/b^2$, pero

$$I_X(b) = \mathbf{V}_b(Y) = 0.$$

Cota de Cramér-Rao

Es deseable disponer de estimadores

- insesgados;
- y con la menor varianza posible.

Vamos a ver que existe una cota, que depende sólo de la “forma” de la función de densidad/masa, que limita cuán pequeña puede llegar ser la varianza de estimadores insesgados.

Ilustraremos el argumento con el caso en el que

- que el conjunto de parámetros Θ es un intervalo de \mathbb{R} ;
- la variable X es finita;
- y su soporte no depende de $\theta \in \Theta$.

Digamos que, para cada $\theta \in \Theta$, la variable X toma un número finito de valores A con probabilidad positiva. Además $\text{sop}_\theta = A$ para cada $\theta \in \Theta$.

Lema 1

En la situación descrita,

$$\mathbf{E}_\theta(Y) = 0 \quad \text{para cada } \theta \in \Theta.$$

Y por tanto

$$I_X(\theta) = \mathbf{V}_\theta(Y) = \mathbf{E}_\theta(Y^2) = \mathbf{E}_\theta\left(\left(\frac{\partial_\theta f(X; \theta)}{f(X; \theta)}\right)^2\right).$$

Demostración. Como para cualquier $\theta \in \Theta$,

$$(*) \quad 1 = \sum_{x \in A} f(x; \theta)$$

(una suma finita), derivando respecto de θ en el intervalo Θ obtenemos

$$0 = \sum_{x \in A} \partial_\theta f(x; \theta) = \sum_{x \in A} \left(\frac{\partial_\theta f(x; \theta)}{f(x; \theta)} \right) f(x; \theta) = \mathbf{E}_\theta(Y).$$

Sea ahora (X_1, \dots, X_n) una muestra aleatoria de X . Cada X_j tiene su variable de información (clónicas e independientes)

$$Y_j = \frac{\partial_\theta f(X_j; \theta)}{f(X_j; \theta)}, \quad \text{para } j = 1, 2, \dots, n,$$

Consideremos

$$Z_n = \sum_{j=1}^n Y_j$$

(un estadístico, pues es función de X_1, \dots, X_n).

Lema 2

Para cada $\theta \in \Theta$,

$$\mathbf{E}_\theta(Z_n) = 0 \quad \text{y} \quad \mathbf{V}_\theta(Z_n) = n I_X(\theta).$$

Sea $T = h(X_1, X_2, \dots, X_n)$ un estimador **insesgado** de θ , es decir,

$$\theta = \mathbf{E}_\theta(T), \quad \text{para todo } \theta \in \Theta,$$

Que reescribimos

$$(\star\star) \quad \theta = \mathbf{E}_\theta(h(X_1, \dots, X_n)) = \sum_{\mathbf{x} \in A^n} h(\mathbf{x}) f(\mathbf{x}; \theta)$$

Derivamos:

$$1 = \sum_{\mathbf{x} \in A^n} h(\mathbf{x}) \left(\sum_{j=1}^n \frac{\partial_\theta f(x_j; \theta)}{f(x_j; \theta)} \right) f(\mathbf{x}; \theta).$$

Es decir,

$$1 = \mathbf{E}_\theta(T \cdot Z_n).$$

Como $\mathbf{E}_\theta(Z_n) = 0$,

$$\text{cov}_\theta(T, Z_n) = \mathbf{E}_\theta(T \cdot Z_n) - \mathbf{E}_\theta(T) \cdot \mathbf{E}_\theta(Z_n) = \mathbf{E}_\theta(T \cdot Z_n) = 1.$$

De la desigualdad (general)

$$\text{cov}_\theta(T, Z_n) \leq \sqrt{\mathbf{V}_\theta(T)} \sqrt{\mathbf{V}_\theta(Z_n)},$$

se deduce que

$$1 \leq \mathbf{V}_\theta(T) \mathbf{V}_\theta(Z_n) = \mathbf{V}_\theta(T) \cdot n I_X(\theta).$$

Teorema 3 (Cramér–Rao, caso finito, soporte independiente de θ)

Para todo estadístico insesgado T de θ ,

$$\text{ECM}_\theta(T) = \mathbf{V}_\theta(T) \geq \frac{1}{n I_X(\theta)}, \quad \text{para todo } \theta \in \Theta.$$

El caso general

Hemos obtenido esta cota bajo las hipótesis

- 1) variable finita;
- 2) soporte independiente de θ .

Mantengamos 2). Denotemos por **sop** al soporte común, para cada $\theta \in \Theta$.

En el argumento anterior hemos derivado dos ecuaciones, (\star) y $(\star\star)$ y hemos usado que la derivada de la suma es la suma de las derivadas.

Si la variable X fuera discreta con soporte A numerable, pero no finito, tendríamos series, en lugar de sumas, y para poder intercambiar serie y derivación hace falta que $f(x; \theta)$ y sus derivadas respecto de θ tiendan a 0 (no demasiado lentamente) cuando $|x| \rightarrow \infty$.

Cuando X es continua, las esperanzas son integrales. Para poder derivar bajo el signo integral en una expresión como

$$(\star') \quad 1 = \int_{\text{sop}} f(x; \theta) dx$$

para obtener que

$$0 = \int_{\text{sop}} \partial_\theta f(x; \theta) dx = \int_{\text{sop}} \frac{\partial_\theta f(x; \theta)}{f(x; \theta)} f(x; \theta) dx \implies \mathbf{E}_\theta(Y) = 0,$$

hace falta que $f(x; \theta)$ y sus derivadas respecto de θ decaigan a cero no demasiado lentamente cuando $|x| \rightarrow \infty$ (por ejemplo, para garantizar que la integral $\int_{\text{sop}} \partial_\theta f(x; \theta) dx$ converge).

Estas condiciones se cumplen para los modelos para X que se usan en la práctica.

Teorema 4 (Cota de Cramér–Rao)

En condiciones muy generales, si sop_θ no depende de θ , entonces para todo estadístico insesgado T de θ se cumple que

$$\mathbf{V}_\theta(T) \geq \frac{1}{n I_X(\theta)}, \quad \text{para todo } \theta \in \Theta$$

A un estimador insesgado T del parámetro θ cuya varianza es justamente la cota de Cramér–Rao, es decir, tal que

$$\mathbf{V}_\theta(T) \cdot I_X(\theta) = \frac{1}{n}, \quad \text{para todo } \theta \in \Theta$$

se le dice **estimador eficiente o insesgado de mínima varianza**.

El caso del soporte dependiente de θ

En este caso, la cota no tiene por qué ser válida.

Ejemplo. $X \sim \text{UNIF}[0, b]$. Como ya vimos (ejemplo 3),

$$Y \equiv -1/b.$$

Para empezar, no se cumpliría que $\mathbf{E}_b(Y) = 0$, como debería. Además, $\mathbf{V}_b(Y) = 0$, y por tanto $I_X(b) = 0$.

Aún así, como $\mathbf{E}_b(Y^2) = 1/b^2$, la cota de Cramér–Rao “debería” ser b^2/n .

Pero ya vimos que el estimador insesgado $T = \frac{n+1}{n} \max(X_1, \dots, X_n)$ tiene varianza

$$\mathbf{V}_b(T) = \frac{1}{n(n+2)} b^2.$$

Observaciones:

- El cálculo del número de información puede ser complicado.
- No es seguro que exista un estimador eficiente (o que al menos sepamos decidir cuál es).
- En el caso en que exista, ¿será único?
- Desde el punto de vista de la eficiencia, ¿qué tal son, por ejemplo, los estimadores que se obtienen por máxima verosimilitud?

Ejemplo 1. Cota de Cramér–Rao para $X \sim \text{EXP}(\lambda)$, cuando queremos estimar $\theta = 1/\lambda$.

Ya sabemos que

$$I_X(\theta) = \frac{1}{\theta^2}.$$

La cota de Cramér–Rao es

$$\mathbf{V}_\theta(T) \geq \frac{\theta^2}{n}.$$

Recordemos que \bar{X} es estimador insesgado de θ y que

$$\mathbf{V}_\theta(\bar{X}) = \frac{\mathbf{V}_\theta(X)}{n} = \frac{\theta^2}{n}.$$

Así que \bar{X} es estimador insesgado de mínima varianza, es decir, estimador eficiente.

Ejemplo 2. Cota de Cramér–Rao para $X \sim \text{POISSON}(\lambda)$, cuando queremos estimar $\theta = \lambda$.

Ya sabemos que

$$I_X(\lambda) = \frac{1}{\lambda}.$$

La cota de Cramér–Rao es

$$\mathbf{V}_\lambda(T) \geq \frac{\lambda}{n}.$$

De nuevo, \bar{X} es estimador insesgado de λ y su varianza es

$$\mathbf{V}_\lambda(\bar{X}) = \frac{\mathbf{V}_\lambda(X)}{n} = \frac{\lambda}{n}.$$

Así que \bar{X} es estimador insesgado de mínima varianza, es decir, estimador eficiente.

Ejemplo 3. Cota de Cramér–Rao para $X \sim \mathcal{N}(0, \sigma^2)$, cuando queremos estimar $\theta = \sigma^2$. Tenemos

$$f(x; \theta) = \frac{1}{\sqrt{2\pi}\sqrt{\theta}} e^{-\frac{1}{2}x^2/\theta} \quad \text{para todo } x \in \mathbb{R}.$$

De manera que

$$\partial_\theta \ln(f(x; \theta)) = \frac{x^2 - \theta}{2\theta^2}.$$

y, por tanto,

$$Y = \frac{X^2 - \theta}{2\theta^2}.$$

La media $\mathbf{E}_\theta(Y) = 0$, pues $\mathbf{E}_\theta(X^2) = \theta$.

Queda calcular

$$I_X(\theta) = \mathbf{V}_\theta(Y) = \mathbf{E}_\theta(Y^2) = \frac{1}{4\theta^4} \mathbf{E}_\theta((X^2 - \theta)^2)$$

Obsérvese que $X = \sqrt{\theta}Z$, donde $Z \sim \mathcal{N}(0, 1)$.

Así que, como $\mathbf{E}(Z^4) = 3$,

$$\mathbf{E}_\theta((X^2 - \theta)^2) = \theta^2 \mathbf{E}_\theta((Z^2 - 1)^2) = \theta^2 \mathbf{E}(Z^4 + 1 - 2Z^2) = \theta^2 (3 + 1 - 2) = 2\theta^2$$

En total

$$I_X(\theta) = \frac{1}{2\theta^2}$$

La cota es $\frac{2\theta^2}{n}$.

S^2 es estimador insesgado de θ y tiene

$$\mathbf{V}(S^2) = \frac{2\theta^2}{n-1}.$$

No se alcanza (por poco) la cota de Cramér–Rao.