

Máxima verosimilitud

Tenemos una variable X discreta con función de masa

$$f(x; \theta),$$

donde $x \in A$ y $\theta \in \Theta$. (X_1, \dots, X_n) es una muestra aleatoria de X .

- **A priori**, la probabilidad, conocido θ , de obtener una realización específica (potencial) (x_1, \dots, x_n) de (X_1, \dots, X_n) viene dada por

$$(\star) \quad \prod_{i=1}^n f(x_i; \theta).$$

- En la práctica (estadística) la situación es justo la contraria: disponemos una realización concreta (x_1, \dots, x_n) , pero desconocemos θ .

Idea: para (x_1, \dots, x_n) dado,

- tomamos como estimación de θ al valor $\hat{\theta}$ que hace máxima la expresión (\star) ;
- y entendemos que $\hat{\theta}$ es el valor de θ más verosímil dada la realización observada de la muestra (x_1, \dots, x_n) .

A priori: probabilidad de realizaciones.

A posteriori, verosimilitud de parámetros.

Llamamos **función de verosimilitud** a la función V

$$\theta \mapsto V(\theta; x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta),$$

donde $(x_1, \dots, x_n) \in A^n$ hace ahora el papel de parámetros.

El estimador de máxima verosimilitud $\mathbf{emv}_\theta(x_1, \dots, x_n)$ de θ es aquel valor $\hat{\theta} \in \Theta$ donde V se hace máxima, suponiendo que haya tal valor. Se trata de un máximo global.

Habitual: considerar

$$LV(\theta; x_1, \dots, x_n) = \ln(V(\theta; x_1, \dots, x_n)) = \sum_{i=1}^n \ln(f(x_i; \theta)),$$

la **log-verosimilitud**. Las funciones V y LV alcanzan el máximo en el mismo punto θ de Θ .

Si X es una **variable continua** con función de densidad $f(x; \theta)$ con $\theta \in \Theta$, la función de verosimilitud se define

$$V(\theta; x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta),$$

y la estimación máximo-verosímil es el valor de θ que maximiza, para una muestra (x_1, \dots, x_n) dada, la función de máximo-verosimilitud.

O quizás la función de log-verosimilitud

$$LV(\theta; x_1, \dots, x_n) = \ln(V(\theta; x_1, \dots, x_n)) = \sum_{i=1}^n \ln(f(x_i; \theta)),$$

En lo que sigue solo escribiremos $V(\theta)$ y $LV(\theta)$.

Obsérvese que \mathbf{emv}_θ es función de x_1, \dots, x_n , pues para cada realización, la función de verosimilitud cambia.

De manera que $\mathbf{emv}_\theta(X_1, \dots, X_n)$ es un **estadístico estimador** del parámetro θ . Que en algunos casos se puede calcular explícitamente.

Ejemplos

Ejemplo 1. $X \sim \text{BER}(p)$. Queremos estimar $p \in [0, 1]$.

X toma sólo los valores 0 y 1. De una realización (x_1, \dots, x_n) de (X_1, \dots, X_n) sólo necesitamos saber el número m de unos que hay en ella (el número de ceros es $n - m$).

La función de verosimilitud V viene dada por

$$p \in [0, 1] \mapsto V(p) = p^m (1 - p)^{n-m}$$

Queremos hallar el valor de p que hace máxima esta expresión.

La función V es

- continua y no negativa;
- se anula en $p = 0$ y en $p = 1$;
- y tiene un máximo en $(0, 1)$.

¿Dónde?

Obsérvese que

$$\begin{aligned}\partial_p V(p) &= m p^{m-1} (1-p)^{n-m} + p^m (n-m) (1-p)^{n-m-1} \\ &= [m(1-p) - (n-m)p] p^{m-1} (1-p)^{n-m-1},\end{aligned}$$

que se anula cuando $m(1-p) = (n-m)p$. Es decir

$$\hat{p} = \frac{m}{n}.$$

La estimación \hat{p} es, en efecto, función de la realización de la muestra (a través de m).

Visto como estadístico, sería

$$\text{emv}_p(X_1, \dots, X_n) \equiv \bar{X}.$$

Ejemplo 2. $X \sim \text{GEO}(p)$. Queremos estimar $p \in [0, 1]$.

La realización (x_1, \dots, x_n) consiste de enteros positivos. La función de verosimilitud es

$$V(p) = \prod_{i=1}^n p(1-p)^{x_j-1} = p^n (1-p)^{\sum_{j=1}^n x_j - n}.$$

Se obtiene que

$$\hat{p} = \frac{n}{\sum_{j=1}^n x_j} = \frac{1}{\frac{1}{n} \sum_{j=1}^n x_j} = \frac{1}{\bar{x}}.$$

Así que

$$\text{emv}_p(X_1, \dots, X_n) \equiv \frac{1}{\bar{X}}.$$

Ejemplo 3. $X \sim \text{UNIF}[0, a]$. Queremos estimar $a > 0$.

La función de densidad de X es

$$f(x; a) = \begin{cases} 1/a; & \text{si } 0 \leq x \leq a, \\ 0; & \text{resto.} \end{cases}$$

Dada una muestra (x_1, \dots, x_n) , la función de verosimilitud es

$$V(a) = \begin{cases} 1/a^n & \text{si } \max\{x_j\} \leq a, \\ 0 & \text{si } \max\{x_j\} > a. \end{cases}$$

El máximo se alcanza justamente en $a = \max\{x_1, \dots, x_n\}$, así que

$$\mathbf{emv}_a(X_1, \dots, X_n) = \max\{X_1, \dots, X_n\}.$$

Ejemplo 4. $X \sim \text{EXP}(\lambda)$. Queremos estimar $\lambda > 0$.

Función de verosimilitud:

$$V(\lambda) = \prod_{i=1}^n \lambda e^{-\lambda x_i} = \lambda^n e^{-\lambda \sum_{i=1}^n x_i}.$$

Obsérvese que $V \rightarrow 0$ cuando $\lambda \downarrow 0$ y cuando $\lambda \uparrow \infty$. Tomamos logaritmos:

$$\text{LV}(\lambda) = n \ln(\lambda) - \lambda n \bar{x}.$$

Derivando e igualando a 0:

$$\partial_{\lambda} \text{LV}(\lambda) = \frac{n}{\lambda} - n \bar{x} = 0 \quad \implies \quad \hat{\lambda} = \frac{1}{\bar{x}}.$$

Así que

$$\mathbf{emv}_{\lambda}(X_1, \dots, X_n) = \frac{1}{\bar{X}}.$$

Ejemplo 5. $X \sim \mathcal{N}(\mu, \sigma^2)$. Hay dos parámetros. Queremos estimar $\mu \in \mathbb{R}$ y $\sigma^2 > 0$.

Función de verosimilitud:

$$\begin{aligned} V(\mu, \sigma^2) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \frac{1}{\sqrt{\sigma^2}} e^{-(x_i - \mu)^2 / (2\sigma^2)} \\ &= \frac{1}{(2\pi)^{n/2}} \frac{1}{(\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \end{aligned}$$

Previo: en el semiplano (μ, σ^2) ,

- Para μ fijo, si $\sigma^2 \rightarrow +\infty$, se tiene que $V(\mu, \sigma^2) \rightarrow 0$.
- Para σ^2 fijo, si $\mu \rightarrow \pm\infty$, también se tiene que $V(\mu, \sigma^2) \rightarrow 0$.

Tomamos logaritmos:

$$LV(\mu, \sigma^2) = \ln \left(\frac{1}{(2\pi)^{n/2}} \right) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2.$$

Y planteamos el sistema:

$$\begin{cases} \partial_{\mu} LV(\mu, \sigma^2) = 0 \\ \partial_{\sigma^2} LV(\mu, \sigma^2) = 0 \end{cases}$$

Solución:

$$\hat{\mu} = \bar{x}, \quad \hat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

Así que

$$\mathbf{emv}_{\mu}(X_1, \dots, X_n) = \bar{X}, \quad \mathbf{emv}_{\sigma^2}(X_1, \dots, X_n) = D^2.$$