

# Estadística

Probabilidades y Estadística (C) - 2019 - Parte 2

# Estadística

POBLACION $\leftrightarrow F$	MUESTRA $X_1, \dots, X_n$ i.i.d. $X_i \sim F$
Parámetro: Valor asociado de $F$ $\theta = \theta(F)$ $\theta$ : valor poblacional	Estimador: estadístico para estimar $\hat{\theta}_n = \hat{\theta}_n(X_1, \dots, X_n)$ $\hat{\theta}_n$ NUEVA VARIABLE ALEATORIA



# Máxima verosimilitud

## Caso discreto

- Modelo:  $\mathcal{M} = \{p(\cdot, \theta), \theta \in \Theta\}$ .
- $\mathbf{x} = x_1, \dots, x_n$  realización de  $X_1, \dots, X_n$  i.i.d.
- Función de verosimilitud asociada a  $\mathbf{x} = x_1, \dots, x_n$ :

$$L(\cdot; \mathbf{x}) : \Theta \rightarrow \mathbb{R}$$

$$L(\theta; \mathbf{x}) = \mathbb{P}(X_1 = x_1, \dots, X_n = x_n), X_i \sim p(\cdot, \theta).$$

$$L(\theta; \mathbf{x}) = \prod_{i=1}^n p(x_i, \theta),$$

Nos interesa ver cuán **verosímil** es que un determinado parámetro haya generado los datos.

# Máxima verosimilitud

## Caso discreto

- Modelo:  $\mathcal{M} = \{p(\cdot, \theta), \theta \in \Theta\}$ .
- $\mathbf{x} = x_1, \dots, x_n$  realización de  $X_1, \dots, X_n$  i.i.d.
- Función de verosimilitud asociada a  $\mathbf{x} = x_1, \dots, x_n$ :

$$L(\cdot; \mathbf{x}) : \Theta \rightarrow \mathbb{R}$$

$$L(\theta; \mathbf{x}) = \mathbb{P}(X_1 = x_1, \dots, X_n = x_n), X_i \sim p(\cdot, \theta).$$

$$L(\theta; \mathbf{x}) = \prod_{i=1}^n p(x_i, \theta),$$

Nos interesa ver cuán **verosímil** es que un determinado parámetro haya generado los datos.

- Propuesta de máxima verosimilitud:

$$h_n(\mathbf{x}) = \operatorname{argmax}_{\theta \in \Theta} L(\theta; \mathbf{x}).$$

o sea

$$L(h_n(\mathbf{x}), \mathbf{x}) \geq L(\theta, \mathbf{x})$$

# Estimador de Máxima verosimilitud

## Caso discreto

Bajo el modelo  $\mathcal{M} = \{p(\cdot, \theta), \theta \in \Theta\}$ , el estimador de máxima verosimilitud para  $\theta$  es la variable aleatoria

$$\hat{\theta}_n = h_n(X_1, \dots, X_n)$$

# Máxima Verosimilitud

## Caso continuo

- Modelo:  $\mathcal{M} = \{f(\cdot, \theta), \theta \in \Theta\}$ , con  $f(\cdot, \theta)$  función de densidad.
- $\mathbf{x} = x_1, \dots, x_n$  realización correspondiente a  $X_1, \dots, X_n$
- Función de verosimilitud:  $L(\cdot; \mathbf{x}) : \Theta \rightarrow \mathbb{R}$

$$L(\theta; \mathbf{x}) = f_{X_1, \dots, X_n}(x_1, \dots, x_n), X_i \sim f(\cdot, \theta).$$

$$L(\theta; \mathbf{x}) = \prod_{i=1}^n f(x_i, \theta),$$

- Propuesta de Máxima Verosimilitud:

$$h_n(\mathbf{x}) = \operatorname{argmax}_{\theta \in \Theta} L(\theta; \mathbf{x}).$$

o sea

$$L(h_n(\mathbf{x}), \mathbf{x}) \geq L(\theta, \mathbf{x})$$

- Definimos el EMV siendo  $\hat{\theta}_n = h_n(X_1, \dots, X_n)$ .

Ejemplo  $\mathcal{E}(\lambda)$ :  $f(x, \lambda) = \lambda e^{-x\lambda} \mathcal{I}_{(0, \infty)}(x)$ .

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{E}(\lambda), \lambda > 0$

$$L(\lambda; \mathbf{x}) = \prod_{i=1}^n f(x_i, \lambda) = \prod_{i=1}^n \lambda e^{-x_i \lambda} \mathcal{I}_{(0, \infty)}(x_i)$$

- si  $x_i \geq 0 \forall i$

$$L(\lambda; \mathbf{x}) = \lambda^n e^{-\lambda \sum_{i=1}^n x_i}$$

- Si consideramos el  $\log L$ , resulta

$$\ell(\lambda; \mathbf{x}) = n \log(\lambda) - \lambda \sum_{i=1}^n x_i$$

- Derivando e igualando a 0 queda

$$\frac{n}{\lambda} - \sum_{i=1}^n x_i = 0 \Rightarrow \text{punto crítico es } 1/\bar{x}_n \quad \text{ver que maximiza!}$$

- $\Rightarrow \hat{\lambda} = 1/\bar{X}_n$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, \vartheta)$ ,  $f(x, \mu, \vartheta) = \frac{1}{\sqrt{2\pi}} \frac{1}{\vartheta} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\vartheta}}$

$$L(\mu, \vartheta; \mathbf{x}) = \prod_{i=1}^n f(x_i, \mu, \vartheta)$$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, 9)$ ,  $f(x, \mu, 9) = \frac{1}{\sqrt{2\pi}} \frac{1}{3} e^{-\frac{1}{2} \frac{(x-\mu)^2}{9}}$

$$L(\mu, 9; \mathbf{x}) = \prod_{i=1}^n f(x_i, \mu, 9) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \frac{1}{3} e^{-\frac{1}{2} \frac{(x_i - \mu)^2}{9}}$$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, 9)$ ,  $f(x, \mu, 9) = \frac{1}{\sqrt{2\pi}} \frac{1}{3} e^{-\frac{1}{2} \frac{(x-\mu)^2}{9}}$

$$L(\mu, 9; \mathbf{x}) = \prod_{i=1}^n f(x_i, \mu, 9) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \frac{1}{3} e^{-\frac{1}{2} \frac{(x_i - \mu)^2}{9}}$$

$$L(\mu, 9; \mathbf{x}) = \left( \frac{1}{\sqrt{2\pi}} \right)^n \left( \frac{1}{3} \right)^n e^{-\frac{1}{2} \frac{\sum_{i=1}^n (x_i - \mu)^2}{9}}$$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, 9)$ ,  $f(x, \mu, 9) = \frac{1}{\sqrt{2\pi}} \frac{1}{3} e^{-\frac{1}{2} \frac{(x-\mu)^2}{9}}$

$$L(\mu, 9; \mathbf{x}) = \left(\frac{1}{\sqrt{2\pi}}\right)^n \left(\frac{1}{3}\right)^n e^{-\frac{1}{2} \frac{\sum_{i=1}^n (x_i - \mu)^2}{9}}$$

- Tomemos logaritmo

$$\ell(\mu, 9; \mathbf{x}) = cte - \frac{1}{2} \frac{\sum_{i=1}^n (x_i - \mu)^2}{9}$$

Maximizar a  $\ell(\mu, 9; \mathbf{x})$  como función de  $\mu$  equivale a minimizar

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

Un par de clases atrás, vimos que  $h(\mu)$  se minimiza en  $\bar{x}_n$

$$\text{EMV de } \mu : \hat{\mu} = \bar{X}_n$$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, \sigma^2)$ ,  $f(x, \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$

$$L(\mu, \sigma^2; \mathbf{x}) = \prod_{i=1}^n f(x_i, \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}}$$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, \sigma^2)$ ,  $f(x, \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$

$$L(\mu, \sigma^2; \mathbf{x}) = \prod_{i=1}^n f(x_i, \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}}$$

$$L(\mu, \sigma^2; \mathbf{x}) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n e^{-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}}$$

$X_1, \dots, X_n$  v.a. i.i.d.  $X_i \sim \mathcal{N}(\mu, \sigma^2)$ ,  $f(x, \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$

$$L(\mu, \sigma^2; \mathbf{x}) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n e^{-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}}$$

- Tomando logaritmo y resolviendo las ecuaciones

$$\frac{\partial \ell(\mu, \sigma^2; \mathbf{x})}{\partial \mu} = 0 \quad \text{y} \quad \frac{\partial \ell(\mu, \sigma^2; \mathbf{x})}{\partial \sigma^2} = 0$$

se obtiene que los EMV de  $\mu$  y  $\sigma^2$  son

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

## Notemos que el estimador ...

$$\hat{\theta}_n \equiv \hat{\theta}_n(X_1, \dots, X_n)$$

- $\hat{\theta}_n$  es una variable aleatoria.
- $\hat{\theta}_n$  tiene distribución (siempre).

*Sampling distribution of  $\hat{\theta}_n$ :  $f_{\hat{\theta}_n}$*

- $\hat{\theta}_n$  tiene (en general) esperanza:  $\mathbb{E}(\hat{\theta}_n) = \int u f_{\hat{\theta}_n}(u) du$
- $\hat{\theta}_n$  tiene (en general) varianza:  $\mathbb{V}(\hat{\theta}_n)$

## Sesgo y Varianza: ejemplo

- $X_i \sim \mathcal{U}(0, \theta)$
- $\hat{\theta}_n = 2\bar{X}_n$ .
- $\tilde{\theta}_n = \max\{X_1, \dots, X_n\}$ .
- Calcule la esperanza y varianza de cada estimador.

## Sesgo - Definiciones (pensando en modelos paramétricos...)

Sesgo (Bias) del estimador  $\hat{\theta}_n$ :

$$\text{sesgo}(\hat{\theta}_n) = \mathbb{E}(\hat{\theta}_n) - \theta \quad \left( \text{sesgo}(\hat{\theta}_n, \theta) = \mathbb{E}_\theta(\hat{\theta}_n) - \theta \right)$$

## Sesgo - Definiciones (pensando en modelos paramétricos...)

Sesgo (Bias) del estimador  $\hat{\theta}_n$ :

$$\text{sesgo}(\hat{\theta}_n) = \mathbb{E}(\hat{\theta}_n) - \theta \quad \left( \text{sesgo}(\hat{\theta}_n, \theta) = \mathbb{E}_\theta(\hat{\theta}_n) - \theta \right)$$

- $\hat{\theta}_n$  se dice INSESGADO si  $\text{sesgo}(\hat{\theta}_n) = 0$  (para todo  $\theta$ )

$$\text{sesgo}(\hat{\theta}_n, \theta) = 0, \forall \theta \quad \equiv \quad \mathbb{E}_\theta(\hat{\theta}_n) = \theta, \quad \forall \theta.$$

*Dicho en palabras, el estimador  $\hat{\theta}_n$  se dice insesgado si su esperanza coincide con el valor de interés que queremos estimar:*

- $(\hat{\theta}_n)_{n \geq 1}$  se dice ASINTOTICAMENTE INSESGADO si

$$\lim_{n \rightarrow \infty} \text{sesgo}(\hat{\theta}_n) = 0 \quad (\text{para todo } \theta)$$

$$\lim_{n \rightarrow \infty} \text{sesgo}(\hat{\theta}_n, \theta) = 0, \forall \theta \quad \equiv \quad \lim_{n \rightarrow \infty} \mathbb{E}_\theta(\hat{\theta}_n) = \theta, \forall \theta$$

## Consistencia (de la sucesión de ESTIMADORES)

*A medida que aumenta el tamaño  $n$  de la muestra, el estimador se acerca a lo que queremos conocer.*

$$\hat{\theta}_n \xrightarrow{\mathcal{P}} \theta, \quad \text{cuando } n \rightarrow \infty$$

## Consistencia (de la sucesión de ESTIMADORES)

*A medida que aumenta el tamaño  $n$  de la muestra, el estimador se acerca a lo que queremos conocer.*

$$\hat{\theta}_n \xrightarrow{\mathcal{P}} \theta, \quad \text{cuando } n \rightarrow \infty$$

**Definición:**  $(\hat{\theta}_n)_{n \geq 1}$  se dice consistente sii

$$\hat{\theta}_n \xrightarrow{\mathcal{P}} \theta, \quad \text{cuando } n \rightarrow \infty, \text{ para todo } \theta.$$

$$\hat{\theta}_n(X_1, \dots, X_n) \xrightarrow{\mathcal{P}} \theta(F), \quad \text{cuando } X_i \sim F, \forall F \text{ en mi modelo.}$$

## Error cuadrático medio (ECM)

$$\text{ECM} : \mathbb{E} \left\{ (\hat{\theta}_n - \theta)^2 \right\} \quad \text{ECM}(\hat{\theta}_n, \theta) : \mathbb{E} \left\{ (\hat{\theta}_n - \theta)^2 \right\}.$$

**Lema:** Si el ECM de un estimador converge a cero entonces vale la consistencia:

$$\mathbb{E} \left\{ (\hat{\theta}_n - \theta)^2 \right\} \longrightarrow 0 \quad \text{implica que} \quad \hat{\theta}_n \longrightarrow^{\mathcal{P}} \theta .$$

## Propiedades

**Lema:** El error cuadrático medio de un estimador se descompone de la siguiente manera:

$$\text{ECM}(\hat{\theta}_n, \theta) = \mathbb{V}(\hat{\theta}_n) + \left\{ \mathbb{E}(\hat{\theta}_n) - \theta \right\}^2$$

*En particular...* Si

$$\mathbb{V}(\hat{\theta}_n) \rightarrow 0 \quad \text{y} \quad \mathbb{E}(\hat{\theta}_n) \rightarrow \theta$$

tenemos que ECM converge a cero, y por lo tanto el estimador es consistente:

$$\hat{\theta}_n \xrightarrow{\mathcal{P}} \theta$$

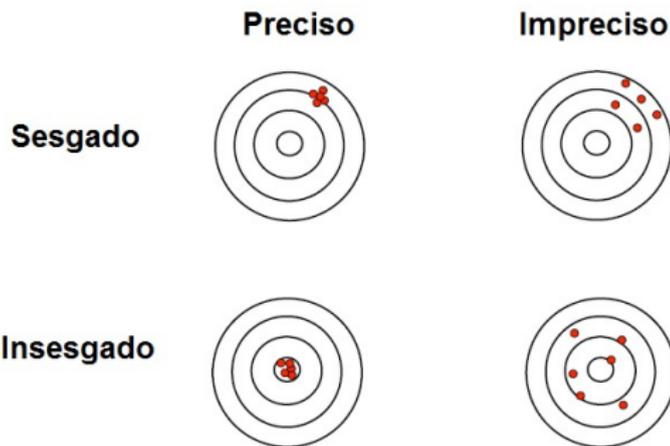
## Precisión y exactitud

**Precisión (varianza):** se refiere a la dispersión del conjunto de valores obtenidos de mediciones repetidas de una magnitud.

**Exactitud (sesgo):** se refiere a cuán cerca del valor real se encuentra el valor medido. En términos estadísticos, la exactitud está relacionada con el sesgo de una estimación.

# Sesgo - Varianza

## Sesgo vs. Precisión



# Propiedades

- Consistencia

$\hat{\theta}_n(X_1, \dots, X_n) \rightarrow \theta(F)$  en probabilidad, cuando  $X_i \sim F$

abreviado:  $\hat{\theta} \rightarrow \theta$

- Error cuadrático medio:  $\text{ECM} = \mathbb{E}\{(\hat{\theta}_n - \theta)^2\}$
- Lema: Si  $\mathbb{E}\{(\hat{\theta}_n - \theta)^2\} \rightarrow 0$ , entonces  $\hat{\theta}_n \xrightarrow{\mathcal{P}} \theta$
- Sesgo:  $\mathbb{E}(\hat{\theta}_n) - \theta$ .
- Estimador insesgado: Sesgo=0:  $\mathbb{E}(\hat{\theta}_n) - \theta$
- Lema:  $\mathbb{E}\{(\hat{\theta}_n - \theta)^2\} = \mathbb{V}(\hat{\theta}_n) + \left\{\mathbb{E}(\hat{\theta}_n) - \theta\right\}^2$
- Si  $\mathbb{V}(\hat{\theta}_n) \rightarrow 0$  y  $\mathbb{E}(\hat{\theta}_n) \rightarrow \theta$ , entonces

$$\mathbb{E}\{(\hat{\theta}_n - \theta)^2\} \rightarrow 0$$