

4/02/2025

A grandes rasgos el proceso de la inferencia estadística...

- ① FA $\rightarrow$ datos $x_1, x_2, \dots, x_n$
- ② Asumir que existe un v.o. X que puede describir el comportamiento agregado del FA

$$X \sim f(x|\theta) \quad \text{ó} \quad X \sim F(x)$$

$\underbrace{\hspace{10em}}_{\text{parámetros}} \qquad \qquad \underbrace{\hspace{10em}}_{\text{n-parámetros}}$

- ③ Necesitamos asumir un modelo de recolección para $x_1, x_2, \dots, x_n$, asumir que son una realización de un m.o. $\equiv$ v.o.i.i.d $X_1, X_2, \dots, X_n$ de $X \sim$

- ④ Bajo estos supuestos podemos hacer
 - 1) Estimación puntual
 - 2) Estimación por intervalos
 - 3) Pruebas de hipótesis

4.1) Estimación puntual. El objetivo es obtener una única mejor estimación del parámetro o cantidad de interés

Ej. Si $X_1, \dots, X_n$ es un m.o. de $X \sim f(x|\theta)$

de alguna manera $\Rightarrow \hat{\theta}_n = h(X_1, X_2, \dots, X_n)$ estimador

$$\hat{\theta}_n = h(x_1, x_2, \dots, x_n) \text{ es función}$$

$\hat{\theta}_n$ es "mejor" con respecto a algún o varios criterios

Estimación - función de los valores observados de la m.a. $(x_1, \dots, x_n)$ que usamos para estimar θ

Estimador - función de la m.a. $X_1, \dots, X_n$ que podemos analizar usando teoría de probabilidad para - entender - sus propiedades al estimar θ .

Propiedades de los estimadores

1) Sesgo. El sesgo es una desviación sistemática de lo que se busca estimar.

$\text{Sesgo}_\theta(\hat{\theta}_n) = E(\hat{\theta}_n) - \theta$,
decimos que el estimador $\hat{\theta}_n$ es insesgado para estimar θ si

$$\text{Sesgo}_\theta(\hat{\theta}_n) = 0 \Leftrightarrow E(\hat{\theta}_n) = \theta$$

2) Var $(\hat{\theta}_n) \Leftrightarrow se(\hat{\theta}_n) = \sqrt{\text{Var}(\hat{\theta}_n)}$

La variancia mide la dispersión "promedio" de $\hat{\theta}_n$ con respecto a $E(\hat{\theta}_n)$, en general se prefieren estimadores con menor variancia o al menos que decrezca conforme n aumenta

(2)

$$\begin{aligned}\text{Var}(\hat{\theta}_n) &= \mathbb{E}((\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n))^2) \\ &= \mathbb{E}(\hat{\theta}_n^2) - \mathbb{E}(\hat{\theta}_n)^2\end{aligned}$$

3) Error cuadrático medio

$$\text{ECM}_{\theta}(\hat{\theta}_n) = \mathbb{E}((\hat{\theta}_n - \theta)^2)$$

mide la desviación promedio, al cuadrado, entre la v.a. $\hat{\theta}_n$ y θ .
Si tenemos dos estimadores $\hat{\theta}_n^1$ y $\hat{\theta}_n^2$ de θ

$\Rightarrow$ un criterio de decisión podría ser el de elegir el que tenga el menor error cuadrático medio.

Teorema

$$\begin{aligned}\text{ECM}_{\theta}(\hat{\theta}_n) &= \text{Sesgo}^2(\hat{\theta}_n) + \text{Var}(\hat{\theta}_n) \\ &= (\mathbb{E}(\hat{\theta}_n) - \theta)^2 + \mathbb{E}((\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n))^2)\end{aligned}$$

Dem

$$\begin{aligned}\text{ECM}_{\theta}(\hat{\theta}_n) &= \mathbb{E}((\hat{\theta}_n - \theta)^2) \\ &= \mathbb{E}((\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n) + \mathbb{E}(\hat{\theta}_n) - \theta)^2) \\ &= \mathbb{E}\left[(\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n))^2 + 2(\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n))(\mathbb{E}(\hat{\theta}_n) - \theta) + (\mathbb{E}(\hat{\theta}_n) - \theta)^2\right]\end{aligned}$$

Explicar scgo /
varianza y ECM
con blancos

$$= \text{Var}(\hat{\theta}_n) + 2 \cancel{\mathbb{E}((\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n))(\mathbb{E}(\hat{\theta}_n) - \theta))} + \mathbb{E}((\mathbb{E}(\hat{\theta}_n) - \theta)^2)$$

$$= \text{Var}(\hat{\theta}_n) + \text{scgo}_{\theta}^2(\hat{\theta}_n) \downarrow$$


4) ¿Qué propiedad es importante actualmente de

$\hat{\theta}_n \xrightarrow{P} \theta$, i.e. $\hat{\theta}_n$ es un estimador consistente
para estimar θ

$n = 10$

$n = 50$

$n = 100$



a medida que aumenta n las estimaciones van cayendo
más cerca de θ , son realizaciones de una v.c.
por eso se dice convergencia en probabilidad

$$\hat{\theta}_n \xrightarrow{P} \theta \iff \lim_{n \rightarrow \infty} P(|\hat{\theta}_n - \theta| > \epsilon) = 0,$$

$$\forall \epsilon > 0.$$

$$5: \hat{\theta}_n \xrightarrow{D} I \sim F_I(y)$$

↑ convergencia en distribución

$$\lim_{n \rightarrow \infty} F_{\hat{\theta}_n}(y) = F_I(y) \leftarrow \text{distribución objetivo}$$

Antes de hacer un ejemplo, recordemos dos resultados fundamentales de un curso de probabilidad

Ley débil de los grandes números (LDGN)

Sea $X_1, X_2, \dots, X_n$ una m.c. de $X \sim \mathcal{F}(X)$, en donde $\mu = \mathbb{E}(X)$ y $\sigma^2 = \text{Var}(X)$. Recordemos que

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\Rightarrow \bar{X}_n \xrightarrow{P} \mu$$

en términos estadísticos, sin importar la distribución de la m.c. si $\mu = \mathbb{E}(X)$ existe

$\Rightarrow \bar{X}_n$ es un estimador consistente para μ

Además sabemos que

$$\begin{aligned} \mathbb{E}(\bar{X}_n) &= \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X) = \mu \end{aligned}$$

$\Rightarrow$ Sin importar la distribución que genere la m.c.

$\bar{X}_n$ es un estimador insesgado para μ .

$$\begin{aligned}
 \text{Var}(\bar{X}_n) &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\
 &= \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \\
 &= \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X) = \frac{G^2}{n}
 \end{aligned}$$

$$\begin{aligned}
 \Rightarrow \text{ECM}_\mu(\bar{X}_n) &= \cancel{\text{Sego}^2_\mu(\bar{X}_n)} + \text{Var}(\bar{X}_n) \\
 &= G^2/n
 \end{aligned}$$

Teorema Central de Límite (TCL)

Sea $X_1, X_2, \dots, X_n$ i.i.d. de $X \sim f(x)$, en donde $\mu = E(X)$ y $G^2 = \text{Var}(X) < \infty$

$$Z_n = \frac{\bar{X}_n - \mu}{G/\sqrt{n}} \xrightarrow{D} Z \sim N(0, 1)$$

En kíbrar otras fórmulas que ayudan a entender el punto.

Para n suficientemente grande, pero fijo,

$$\bar{X}_n \sim N(\mu, G^2/n)$$

Acebrar de analizar a $\bar{X}_n$ como estimador de μ en el caso NO paramétrico. Lo que encontramos es que es un excelente estimador

Ejemplo 2

Sea $X_1, X_2, \dots, X_n$ una m.c. de $X \sim \text{Bernalli}(\theta)$

$\Rightarrow$ digamos que queremos evaluar qué tan buen estimador es

$\bar{X}_n$ de θ , ¿por qué estimar θ con $\bar{X}_n$?

1) Sesgo $E(\bar{X}_n) = E(X) = \theta$

2) Varianza $Var(\bar{X}_n) = \frac{1}{n} Var(\theta) = \frac{\theta(1-\theta)}{n}$

3) $E(M_\theta(\bar{X}_n)) = \frac{\theta(1-\theta)}{n}$

4) $\bar{X}_n \xrightarrow{P} \theta$, con estimador consistente de θ

LOG N

5) $\frac{\bar{X}_n - \theta}{\sqrt{\frac{\theta(1-\theta)}{n}}} \xrightarrow{D} Z \sim N(0, 1)$

$\Rightarrow$ for n suf. grande $\bar{X}_n \sim N(\theta, \frac{\theta(1-\theta)}{n})$