

- La página del curso ya está lista.

3: Modelos e inferencia estadística

Como vimos la clase pasada, en inferencia estadística siempre asumiremos que

① el fenómeno aleatorio de interés (la variable que nos interesa de nuestra población) es una v.a. \underline{X}

② $\underline{X} \rightsquigarrow f(x|\theta)$
ó
 $\underline{X} \rightsquigarrow f(x)$

Subconjunto menor de los egresados de la LCD del IIMAS $\equiv \underline{X}$

$\underline{X} \rightsquigarrow LN(\mu, \sigma^2)$

③ Obtener datos de nuestra población

$$X_{1:n} = x_1, x_2, \dots, x_n$$

④ Usar esos datos para estimar la característica de \underline{X} que nos interesa

- θ
- $\mu = E(\underline{X})$
- $f(x|\theta)$
- $F(x)$
- $P(\underline{X} > c)$

Es necesario describir con más detalle los casos (2) y (3)

En (2) estamos suponiendo que un modelo estadístico describe la variable de interés de nuestra población. Tendremos 2 clases de modelos

- Paramétricos
- No paramétricos

Un modelo estadístico M es simplemente un conjunto de distribuciones que en teoría pueden describir la variable de interés.

$$M = \{ f(x|\mu, \sigma^2) = \frac{1}{x\sqrt{2\pi\sigma^2}} e^{-\frac{(\log(x) - \mu)^2}{2\sigma^2}} \mid \mu \in \mathbb{R} \text{ y } \sigma > 0 \}$$

↑ modelo paramétrico por lo poder describir mediante μ y σ^2
2 parámetros.

Un modelo paramétrico puede describirse mediante un número finito de parámetros. En general los modelos paramétricos los describiremos como

$$M = \{ f(x|\theta) \mid \theta \in \Omega \}$$

en donde θ es el parámetro desconocido o vector de parámetros

$$\theta = (\theta_1, \theta_2, \dots, \theta_k)$$

Un modelo estadístico no paramétrico es un conjunto \underline{M} que no se puede describir mediante un número finito de parámetros.

$M = \{ \text{todos los funciones de distribución} \}$

$M = \{ \text{todas las funciones de distribución para v.c. continuas} \}$

$M = \{ \text{todas las funciones de distribución simétricas} \}$

En ③ tener que considerar que los datos x_1, x_2, \dots, x_n están sujetos a la variabilidad de observaciones individuales y que si se obtiene otro conjunto de datos este no será el mismo

\Rightarrow se asume que el modelo de recolección de la información es una muestra aleatoria \equiv v.o.i.i.d. de \underline{M}

X_1, X_2, \dots, X_n y que x_1, x_2, \dots, x_n es simplemente una realización de este v.c.

Sea X_1, X_2, \dots, X_n un m.c. de $f(x|\theta)$

\Rightarrow 1) $X_i \sim f(x|\theta)$ para $i=1, \dots, n$

2) $X_i \perp X_j \forall i \neq j$

en este caso $f(x_1, x_2, \dots, x_n | \theta) = \prod_{i=1}^n f(x_i | \theta)$

$\underbrace{\hspace{10em}}$ la distribución conjunta de la m.a
 $\underbrace{\hspace{10em}}$ producto de las marginales y cada $f(x_i | \theta)$ es simplemente $f(x_i)$ evaluada en $\underline{x_i}$.

Ahora describiré con más detalle el paso (4)

Existen 3 problemas principales que atacan la inferencia estadística:

- i) Estimación puntual
- ii) Estimación por intervalo
- iii) Prueba de hipótesis.

i) Estimación puntual. Aquí el objetivo es obtener una única mejor estimación para un parámetro de interés.

- El parámetro que gobierna el comportamiento del modelo paramétrico $\rightarrow \hat{\theta}_n$
- La distribución empírica se aproxima a $f(x)$ en el modelo NO paramétrico $\hat{f}_n(x)$.

- La distribución que aproxima $f(x)$ en el modo NO paramétrico. $\hat{f}_n(x)$

Vamos a concentrarnos en la estimación de Θ usando $\hat{\Theta}_n$

$$\hat{\Theta}_n = \begin{cases} g(x_1, x_2, \dots, x_n) & \leftarrow \text{estimación} \\ g(\bar{X}_1, \bar{X}_2, \dots, \bar{X}_n) & \leftarrow \text{estimador} \end{cases}$$

Tener el supuesto de que $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_n$ es un m.a. de $f(x)$ y x_1, x_2, \dots, x_n son los valores observados de la m.o.

Primero construir un estimador de Θ que es una función únicamente de la m.o. y que usaremos para estimar Θ .

$$\hat{\Theta}_n = g(\bar{X}_1, \bar{X}_2, \dots, \bar{X}_n) \dots \text{v.o.}$$

Utilizando la teoría de probabilidad podemos evaluar las cualidades del estimador $\hat{\Theta}_n$ para estimar Θ .

① Sesgo. El sesgo es un desvío sistemático de lo que buscamos estimar y se mide como

$$\text{Sesgo}_\theta(\hat{\theta}_n) = \mathbb{E}(\hat{\theta}_n) - \theta$$

Decimos que el estimador $\hat{\theta}_n$ es insesgado para estimar θ si

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

② Error cuadrático medio

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

si tenemos 2 estimadores de θ , $\hat{\theta}_n^1$ y $\hat{\theta}_n^2$
 \Rightarrow se prefiere el que tenga menor error cuadrático medio.

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

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

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

$$+ 2 \mathbb{E}((\hat{\theta}_n - \mathbb{E}(\hat{\theta}_n))(\mathbb{E}(\hat{\theta}_n) - \theta))$$

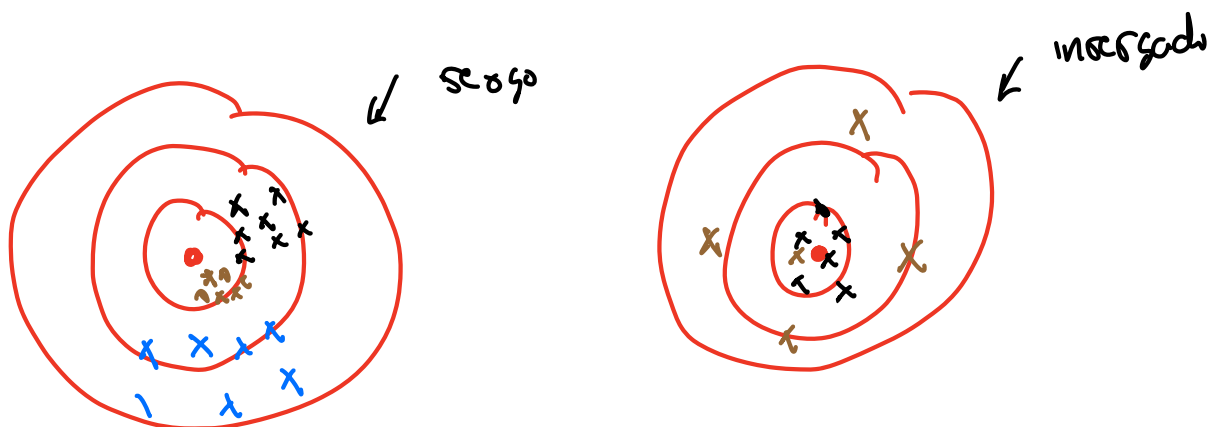
$$+ \mathbb{E}((\mathbb{E}(\hat{\theta}_n) - \theta)^2)$$

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

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

$$E(M_\theta(\hat{\Theta}_n)) = \text{Var}(\hat{\Theta}_n) + \text{Sesgo}^2_\theta(\hat{\Theta}_n)$$

Sesgo, Varianza y error cuadrático medio



③ Consistencia, una propiedad esencial de cualquier estimador es que al aumentar el tamaño de muestra la estimación vaya mejorando

$\hat{\Theta}_n \xrightarrow{n \rightarrow \infty} \Theta$, pero $\hat{\Theta}_n$ es un v.o.
 esto es muy restrictivo

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

$\forall \epsilon > 0$

Ley débil de los grandes números (LDGN)

Sea X_1, X_2, \dots, X_n una m.c. de $X \sim^d f(x)$
y $\mu = \mathbb{E}(X)$

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

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

④ Distribución de muestras de $\hat{\theta}_n$ (asintótica)

¿Cómo se distribuye $\hat{\theta}_n$?

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

¿Cómo se distribuye $\hat{\theta}_n$ para n suf. grande?

Ejemplo

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

$$\hat{\theta}_n = \bar{X}_n$$

- Segs
- ECM
- Consistency
- Distributional analysis