

Clase 29/05/2023.

(1)

En la clase anterior vimos la definición de estadístico y estimador. Podemos entonces repasarla:

Sea X_1, X_2, \dots, X_n una muestra aleatoria simple de una v.a. X con distribución F_X . Esta expresión m.a.s. significa que las v.a. $\{X_j\}_{j=1}^n$ son independientes y poseen la misma distribución F_X .

Definimos entonces un estadístico a una función de (X_1, X_2, \dots, X_n) : $T(X_1, \dots, X_n)$ es decir una función de la m.a.s.

Un estimador es un estadístico que nos otorga una información de un parámetro asociado a la distribución F_X .

De esta manera nuestro modelo será una función de distribución que dependerá de un parámetro θ que puede ser escalar o vectorial. Cuando el parámetro es escalar diremos que $F_X(\cdot, \theta)$ es una familia uniparamétrica.

Si $\vec{\theta} \in \mathbb{R}^d$ esto es $\vec{\theta} = (\theta_1, \theta_2, \dots, \theta_d)$ en este caso el modelo será $F_X(\cdot, \vec{\theta})$ multiparamétrica.

Ejemplos de estas situaciones son

1.- B_1, B_2, \dots, B_n son Bernoullis con parámetro

θ y sabemos que cada $B_j \stackrel{d}{\sim} \text{Bernoulli}(\theta)$

2.- También podemos tener P_1, P_2, \dots, P_n una

Una m.a.s. de una Poisson con parámetro λ ; (2)
es decir la función de probabilidad

$$P(P=k) = e^{-\lambda} \frac{\lambda^k}{k!}$$

3.- Podemos tener V_1, V_2, \dots, V_n una muestra aleatoria simple de una uniforme en el intervalo $[0, \theta]$ y la densidad en este caso es

$$v(x) = \begin{cases} \frac{1}{\theta} & 0 \leq x \leq \theta \\ 0 & \text{en otra parte.} \end{cases}$$

El parámetro aquí es el número positivo θ .

4.- También podemos tener una muestra de una exponencial con parámetro λ . Esto es E_1, E_2, \dots, E_n son todas exponenciales con función de densidad

$$e(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & \text{en otra parte} \end{cases}$$

y el parámetro es el valor $\lambda > 0$.

5.- Por último podemos considerar el modo de una $N(\mu, \sigma^2)$. Esto es Z_1, Z_2, \dots, Z_n es una m.a.s. cada una de las Z_i tiene densidad

$$f_Z(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

En este caso tenemos dos parámetros (μ, σ^2) .

En la clase pasada diseñamos un primer método⁽³⁾ de estimación que llamamos el "Método de los momentos" y que se basaba en la LGN. Sabemos que si X_1, X_2, \dots, X_n es una muestra aleatoria simple de una X con distribución F_X y sabemos que $E(X) = \mu$ entonces

$$\bar{X}_n = \frac{X_1 + \dots + X_n}{n} \xrightarrow{P} E(X) = \mu.$$

Además si $E(|X|^k) < +\infty$ entonces también se tiene que

$$\bar{m}_n = \frac{X_1^n + \dots + X_n^n}{n} \xrightarrow{P} E(X^n) = m_n$$

El método de los momentos consiste en igualar los momentos empíricos a los verdaderos momentos y al despejar encontrar $\hat{\theta}$ el estimador del parámetro.

Ejemplo: Si P_1, P_2, \dots, P_n es una m.a.s de una Poisson de parámetro λ . Entonces

$$E(P) = e^{-\lambda} \sum_{k=1}^{\infty} k \frac{\lambda^k}{k!} = \lambda e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = \lambda$$

luego el estimador de λ por el método de los momentos es

$$\hat{\lambda}_n = \frac{P_1 + P_2 + \dots + P_n}{n}$$

y $\hat{\lambda}_n \xrightarrow{P} \lambda$ (Decimos que el estimador es

Consistente).

En esta clase introduciremos un nuevo método de estimación que llamaremos "Método de máxima verosimilitud".

Para introducirlo consideremos una m.a.s. X_1, X_2, \dots, X_n de una distribución $F_X(\cdot, \theta)$

Es decir la familia depende del parámetro θ .

Supongamos (esto no es en absoluto necesario) que

X posee densidad $f(x, \theta)$ lo que implica,

debido a que las v.a. son independientes, que la densidad del vector (X_1, X_2, \dots, X_n) resulta ser

$$f(x_1, \theta) f(x_2, \theta) \dots f(x_n, \theta) = \prod_{j=1}^n f(x_j, \theta).$$

El método consiste en reemplazar los x_j de arriba por las observaciones (x_1, x_2, \dots, x_n) y construir la función de verosimilitud

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

y también se logaritmo

$$l_n(\theta) = \log L_n(\theta) = \sum_{j=1}^n \log f(x_j, \theta).$$

El método consiste en definir el estimador de máxima verosimilitud como aquel $\hat{\theta}_n$ que

Como el valor que maximiza $L_n(\theta)$ o $\mathcal{L}_n(\theta)$ ⁽⁵⁾
esto se escribe

$$\hat{\theta}_n = \arg \max L_n(\theta)$$

Para simplificar consideremos algunos ejemplos

Ejemplo 1.-

Sea E_1, E_2, \dots, E_n una muestra aleatoria simple de una exponencial con parámetro λ . Entonces la verosimilitud se escribe

$$L_n(\lambda) = \lambda^n \prod_{j=1}^n e^{-\lambda x_j}$$

y su logaritmo

$$\mathcal{L}_n(\lambda) = n \log \lambda - \lambda \sum_{j=1}^n x_j$$

para encontrar el máximo derivamos

$$\mathcal{L}'_n(\lambda) = \frac{n}{\lambda} - \sum_{j=1}^n x_j = 0$$

igualamos a cero y así obtenemos

$$\hat{\lambda}_n = \left(\frac{1}{n} \sum_{j=1}^n x_j \right)^{-1} = \left(\bar{X}_n \right)^{-1}$$

y como un adicional tenemos $\bar{X}_n \xrightarrow{LGN} E(X) = 1/\lambda$

luego

$$\hat{\lambda}_n \xrightarrow{P} \lambda.$$

Otro ejemplo importante es el de la gaussiana $N(\mu, \sigma^2)$

Ejemplo 2: Z_1, Z_2, \dots, Z_n es una m.a.s de una gaussiana con densidad

$$\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Luego $L_n(\mu, \sigma^2) = \frac{1}{(2\pi)^{n/2} \sigma^n} \prod_{j=1}^n e^{-\frac{(X_j - \mu)^2}{2\sigma^2}}$

y su logaritmo

$$\ln(\mu, \sigma^2) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \sum_{j=1}^n \frac{(X_j - \mu)^2}{2\sigma^2}$$

Ahora el logaritmo de la verosimilitud es una función de dos variables y para conseguir los puntos que hacen el máximo debemos derivar con respecto a cada una de las variables e igualar a cero.

$$\textcircled{1} \frac{\partial \ln}{\partial \mu} = -\frac{1}{\sigma^2} \sum_{j=1}^n (X_j - \mu) = 0$$

$$\sum_{j=1}^n X_j - n\mu = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{j=1}^n X_j$$

$$\textcircled{2} \frac{\partial \ln}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \sum_{j=1}^n \frac{(X_j - \mu)^2}{2\sigma^4} = 0$$

Entonces obtenemos despejando

$$-n\frac{\sigma^2}{2} + \sum_{j=1}^n \frac{(X_j - \mu)^2}{2} = 0$$

$$\Rightarrow \sigma_n^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2$$

y como ya habíamos visto que $\hat{\mu} = \bar{X}_n$

$$\hat{\sigma}_n^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2$$

Esto de estimadores fueron los mismo que obtuvimos por el método de los momentos y que fueron analizados en la clase pasada para así obtener su comportamiento.

El próximo ejemplo es importante pues muestra que para encontrar el punto que hace máxima a la Verosimilitud no siempre se puede derivar la función.

Ejemplo 3.-


Supongamos que X_1, X_2, \dots, X_n es una muestra aleatoria simple de una variable uniforme en el intervalo $[0, \theta]$ con $\theta > 0$. Como sabemos la densidad de una tal variable es

$$v(\theta) = \begin{cases} \frac{1}{\theta} & \text{para } x \in [0, \theta] \\ 0 & \text{en otro caso.} \end{cases}$$

Entonces la verosimilitud es

$$L_n(\theta) = \begin{cases} \frac{1}{\theta^n} & \text{si } X_i < \theta \text{ para todo } i \\ 0 & \text{en otro caso} \end{cases}$$

La figura siguiente nos muestra su comportamiento



De la observación de la figura se ve que
 el $\arg \max L_n(\theta) = \max_{1 \leq j \leq n} X_j$.

Ejemplo 4.

Supongamos que X_1, X_2, \dots, X_n es una m.a.s. de una v.a. Binomial S_N de parámetros p .

Sabemos que

$$P(S_N = k) = \binom{N}{k} p^k (1-p)^{N-k}$$

donde $k = 0, 1, 2, \dots, N$. De esta forma la función de verosimilitud se escribe:

$$L_n(p) = \prod_{j=1}^n \binom{N}{X_j} p^{X_j} (1-p)^{N-X_j}$$

Si tomamos el logaritmo tenemos

$$L_n(p) = \sum_{j=1}^n \log \binom{N}{X_j} + \sum_{j=1}^n (\log p) X_j + (N - X_j) \log(1-p)$$

Entonces al derivar

$$\frac{dL_n}{dp} = \frac{1}{p} \sum_{j=1}^m X_j - \frac{1}{(1-p)} \sum_{j=1}^m (N - X_j) = 0$$

$$= \frac{1}{p} \sum_{j=1}^m X_j + \frac{1}{(1-p)} \sum_{j=1}^m X_j = \frac{1}{(1-p)} Nm$$

$$= \left(\frac{1}{p} + \frac{1}{1-p} \right) \sum_{j=1}^m X_j = \frac{1}{(1-p)} Nm$$

$$\Rightarrow \frac{1}{p(1-p)} \sum_{j=1}^m X_j = \frac{1}{(1-p)} Nm$$

$$\Rightarrow \boxed{\frac{1}{Nm} \sum_{j=1}^m X_j = \hat{p}}$$

Debemos entonces calcular la esperanza de este estimador y así obtener

$$E \hat{p} = \frac{1}{Nm} (Np) m = p.$$

Luego la esperanza del estimador es el verdadero parámetro. Esto último no lleva entonces a la definición siguiente.

Definición: El sesgo de un estimador $\hat{\theta}$ es definido por $\boxed{\text{Sesgo}(\hat{\theta}) = E \hat{\theta} - \theta}$

Un estimador es insesgado si:

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

Otro concepto importante para medir la bondad de un estimador es el siguiente:
El error cuadrático ^{medio} de un estimador se define

$$\text{ECM}(\hat{\theta}) = E[(\hat{\theta} - \theta)^2].$$

Podemos entonces obtener la descomposición siguiente

$$\begin{aligned} E[(\hat{\theta} - \theta)^2] &= E[(\hat{\theta} - E(\hat{\theta}) + [E(\hat{\theta}) - \theta])^2] \\ &= E[(\hat{\theta} - E(\hat{\theta}))^2] + 2E[(\hat{\theta} - E(\hat{\theta}))(E(\hat{\theta}) - \theta)] \\ &\quad + (E(\hat{\theta}) - \theta)^2 \\ &= E[(\hat{\theta} - E(\hat{\theta}))^2] + (E(\hat{\theta}) - \theta)^2 \\ &= \text{Var}(\hat{\theta}) + [\text{Sesgo}(\hat{\theta})]^2 \end{aligned}$$

En otras palabras

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