

TEMA 4. ESTIMACIÓN PUNTUAL PARAMÉTRICA

1. PROPIEDADES DE LOS ESTIMADORES PUNTUALES

1. Estimador centrado (o insesgado):

$$T(x_1, \dots, x_n)$$

$T(\vec{x})$ es un estimador centrado de θ (o de $h(\theta)$) si

$$E_{\theta}[T(\vec{x})] = h(\theta)$$

• Sesgo de un estimador: $b_{\theta}(T) = E_{\theta}[T(\vec{x}) - h(\theta)]$

• Ejemplos:

$$E[\bar{X}] = \mu$$

$$E[a_k] = \alpha_k$$

$$E[b_2] \neq \sigma^2 \rightarrow \text{Varianza no centrada}$$

$$E[S^2] = \sigma^2 \rightarrow \text{Covarianza sí centrada}$$

2. Estimador consistente:

Sea $T(\vec{x})$ un estimador de θ y sean $T_1(\vec{x}), \dots, T_n(\vec{x})$,

una sucesión de estimadores que representan a T para diferentes tamaños muestrales. Diremos que $T(\vec{x})$ es consistente para θ si la sucesión $\{T_n\}$ converge en probabilidad a θ .

$$\lim_{n \rightarrow \infty} P_{\theta}\{ |T_n - \theta| \leq \varepsilon \} = 1, \forall \varepsilon > 0$$

• Ejemplos:

$$a_k \xrightarrow{c.s.} \alpha_k \Rightarrow a_k \xrightarrow{P} \alpha_k \Rightarrow \{a_k\} \text{ consistente}$$

$$b_k \xrightarrow{c.s.} \beta_k \Rightarrow b_k \xrightarrow{P} \beta_k \Rightarrow \{b_k\} \text{ consistente}$$

• Proposición: (Condición de suficiencia para la consistencia)

Si $\{T_n\}$ es una sucesión de estimadores tal que $\forall \theta \in \Theta$:

$$\lim_{n \rightarrow \infty} E_{\theta}[T_n(\vec{x})] = \theta$$

$$\lim_{n \rightarrow \infty} V_{\theta}[T_n(\vec{x})] = 0$$

Entonces la sucesión es consistente

- Demostración: (Usaremos Teoremas)

$$P_{\theta} \{ |T_n - \theta| > \varepsilon \} \leq \frac{E_{\theta} [(T_n - \theta)^2]}{\varepsilon^2}$$

$$E_{\theta} [T_n^2 + \theta^2 - 2\theta T_n] = E_{\theta} [T_n^2] + \theta^2 - 2\theta E_{\theta} [T_n] + (E_{\theta} [T_n])^2 - (E_{\theta} [T_n])^2 = \\ = V_{\theta} + (E_{\theta} [T_n] - \theta)^2$$

$$P_{\theta} \{ |T_n - \theta| > \varepsilon \} \leq \frac{V_{\theta} + (E_{\theta} [T_n] - \theta)^2}{\varepsilon^2} \xrightarrow{n \rightarrow \infty} 0$$

$\Rightarrow T_n$ es consistente

- $X \sim \text{Bernoulli}(\theta)$, $x_1, \dots, x_n$, $T_n = \frac{1}{n+2} \left(\sum_{i=1}^n x_i + 1 \right)$ ¿Es consistente?

$$E[T_n] = \frac{1}{n+2} \left(\sum_{i=1}^n E[x_i] + 1 \right) = \frac{1}{n+2} \left(\sum_{i=1}^n \theta + 1 \right) = \frac{n\theta + 1}{n+2}$$

$$\lim_{n \rightarrow \infty} E[T_n] = \theta$$

$$V[T_n] = \frac{1}{(n+2)^2} \left(\sum_{i=1}^n V[x_i] \right) = \frac{1}{(n+2)^2} n\theta(1-\theta)$$

$$\lim_{n \rightarrow \infty} V[T_n] = 0$$

$\Rightarrow T_n$ es consistente

2. CRITERIOS DE COMPARACIÓN DE ESTIMADORES

Error cuadrático medio del estimador T

$$ECM_T(\theta) = E_{\theta} [(T(x_1, \dots, x_n) - \theta)^2]$$

$$ECM_T(\theta) = E_{\theta} [T^2 + \theta^2 - 2\theta T] = E_{\theta} [T^2] + \theta^2 - 2\theta E_{\theta} [T] - (E_{\theta} [T])^2 + (E_{\theta} [T])^2 = \\ = V_{\theta}(T) + (E_{\theta} [T] - \theta)^2 = V_{\theta}(T) + b_{\theta}^2(T)$$

- T, T' estimadores de θ :

$$ECM_{T'}(\theta) \leq ECM_T(\theta) \quad \forall \theta \in \Theta$$

T mejor que T'

T' inadmisibles

Restringimos el criterio de búsqueda:

$$T_1, b_{\theta}(T) = 0$$

T minimiza la varianza ($V_{\theta}(T)$ mínimo)

Es decir, entre los estimadores centrados, nos quedamos con el que tenga menor varianza

• Ejemplos:

1) $X \sim \text{Bernoulli}(\theta)$, $x_1, \dots, x_n$ m.a.s

$$E.C.M_T(\theta) = V_\theta(T) + b_\theta^2(T) = \frac{\theta(1-\theta)}{n} + 0 = \frac{\theta(1-\theta)}{n}$$

$$T(x_1, \dots, x_n) = \bar{x}$$

$$h(\theta) = \theta$$

$$E_\theta[X] = \theta, \quad E[\bar{X}] = \theta$$

$$V[X] = \theta(1-\theta), \quad V[\bar{X}] = \frac{1}{n^2} n \theta(1-\theta) = \frac{\theta(1-\theta)}{n}$$

2) $X \sim N(\mu, \sigma^2)$, $x_1, \dots, x_n$ m.a.s

• $T(x_1, \dots, x_n) = \bar{X}$, σ^2 conocido
 $\theta = \mu$

$$E[\bar{X}] = \mu \Rightarrow b_\theta(T) = 0$$

$$V[\bar{X}] = \frac{\sigma^2}{n}$$

$$E.C.M_T(\theta) = V_\theta(T) = \sigma^2/n$$

• μ conocido, $\theta = \sigma^2$:

$$T(x_1, \dots, x_n) = S^2$$

$$E[S^2] = \sigma^2$$

$$V[S^2] = \frac{2\sigma^4}{(n-1)}$$

$$(n-1) \frac{\chi_{n-1}^2}{\sigma^2}$$

$$V(\chi_{n-1}^2) = 2(n-1)$$

$$E.C.M_{S^2}(\sigma^2) = \frac{2\sigma^4}{(n-1)}$$

• $T(x_1, \dots, x_n) = b_2$

$$E[b_2] = \sigma^2 \left(\frac{n-1}{n} \right)$$

$$b_2 = \frac{S^2(n-1)}{n}$$

$$V[b_2] = V\left[\frac{S^2(n-1)}{n}\right] = \frac{(n-1)^2}{n^2} \cdot \frac{2\sigma^4}{(n-1)} = \frac{2\sigma^4(n-1)}{n^2}$$

$$E.C.M_{b_2}(\sigma^2) = \frac{(2n-1)\sigma^4}{n^2} = V[b_2] + b_2^2 = \left(\frac{2\sigma^4(n-1)}{n^2} \right) + \left(\frac{\sigma^4(n-1)^2}{n^2} \right)$$

$\Rightarrow$ Nos quedaríamos con b_2

• Teorema 2:

Si existe T , ECMV, para $h(\theta)$, T es único.

• Teorema de Rao-Blackwell:

$\left. \begin{array}{l} \underline{h(\theta)} \\ \underline{T \in U_h} \\ \underline{S \text{ suficiente}} \end{array} \right\} \text{Entonces } \underline{H(S) = E[T|S]} :$
 1) $H(S) \in U_h$
 2) $V(H(S)) \leq V(T), \forall \theta \in \theta$

• Demostración:

1) $E[H(S)] = E[E[T|S]] = E[T] = h(\theta) \Rightarrow H(S) \text{ centrado}$

$$(H(S))^2 = (E[T|S])^2 = E[T^2|S] - \underbrace{V[T|S]}_0 \leq E \underbrace{[T^2|S]}_\infty$$

$$E[(H(S))^2] < \infty$$

2) $V(H(S)) = V(E[T|S]) \leq V(T)$

• Teorema de Lehmann-Scheffé:

$\left. \begin{array}{l} \underline{h(\theta)} \\ \underline{\text{Si existe } T \in U_h} \\ \underline{S \text{ suficiente y completo}} \end{array} \right\} \text{Entonces } \underline{H(S) = E[T|S]} :$
 $H(S)$ ECMV para $h(\theta)$

• Demostración:

S suficiente y completo, T centrado

1) Si solo existe un estadístico centrado es el ECMV

2) $T, T', \dots, E[T] = E[T'] = h(\theta)$

• S suficiente: $\left. \begin{array}{l} E[T|S] \text{ fun. de } S \\ E[T'|S] \text{ fun. de } S \end{array} \right\}$

$$E[g(S)] = E[E[T|S]] - E[E[T'|S]] = E[T] - E[T'] = 0$$

• S completo: $g(S) \stackrel{c.s.}{=} 0 \Rightarrow E[T|S] = E[T'|S]$

$$\left. \begin{array}{l} T' \in U_h \\ S \text{ suficiente} \end{array} \right\} \Rightarrow \begin{array}{l} V(E[T'|S]) \leq V(T) \quad \forall \theta \in \theta \\ \parallel \\ V(E[T|S]) \\ \parallel \\ V(H(S)) \end{array}$$

$\Rightarrow H(S) \text{ ECMV para } h(\theta)$

• Ejemplos:

1) $X \sim \text{Poisson}(\theta), \theta > 0$

$x_1, \dots, x_n$

$h(\theta) = \theta$

$\Rightarrow$ Buscamos un estadístico suficiente:

$$P_\theta(x_1, \dots, x_n) = \frac{1}{\prod_{i=1}^n x_i!} e^{-n\theta} \theta^{\sum_{i=1}^n x_i} = h(\vec{x}) c(\theta) e^{(\sum_{i=1}^n x_i) \ln \theta}$$

F. exponencial uniparamétrica

$S(x_1, \dots, x_n) = \sum_{i=1}^n x_i$ suficiente

• Veamos si es completo:

$$\begin{aligned} \theta &\xrightarrow{G} \mathbb{R}^1 \\ \theta &\longrightarrow \ln \theta = \gamma \\ \theta &> 0 \end{aligned}$$



Contiene un abierto de $\mathbb{R}^1 \Rightarrow S = \sum_{i=1}^n x_i$ con

1) $E[S] = E[\sum_{i=1}^n x_i] = \sum_{i=1}^n E[x_i] = n\theta$

$h(\theta) = \theta$

$H(S) = \bar{X}$

$E[\bar{X}] = \theta \Rightarrow \underline{\underline{\bar{X} \in \text{CMV}}}$ para $h(\theta) = \theta$

2) $X \sim \text{Poisson}(\theta), \theta > 0$

$x_1, \dots, x_n$

$h(\theta) = e^{-\theta}$

$S(x_1, \dots, x_n) = \sum_{i=1}^n x_i$ suficiente > completo para θ

$H(S) = E[w|S]$

$w \in \mathcal{U}_h$

$P_\theta(x) = \frac{1}{x!} e^{-\theta} \cdot \theta^x$

$w = \begin{cases} 1 & x_1 = 0 \\ 0 & \text{En cualquier otro caso} \end{cases}$

$E[w] = 1 \cdot \Pr(x_1 = 0) + 0 \cdot \Pr(\text{otro caso}) = e^{-\theta}$

$$\begin{aligned} H(S) &= E[w|S] = E[w | \sum_{i=1}^n x_i = t] = 1 \cdot \Pr(w=1 | \sum_{i=1}^n x_i = t) + 0 \cdot \Pr(w=0 | \sum_{i=1}^n x_i = t) \\ &= \Pr(x_1 = 0 | \sum_{i=1}^n x_i = t) = \frac{\Pr(x_1 = 0, \sum_{i=2}^n x_i = t)}{\Pr(\sum_{i=1}^n x_i = t)} = \frac{\Pr(x_1 = 0, \sum_{i=2}^n x_i = t)}{\Pr(\sum_{i=1}^n x_i = t)} \end{aligned}$$

$$= \frac{\Pr(X_1=0) \cdot \Pr\left(\sum_{i=2}^n X_i = t\right)}{\Pr\left(\sum_{i=1}^n X_i = t\right)} = \frac{(e^{-\theta}) \frac{1}{t!} e^{-(n-1)\theta} ((n-1)\theta)^t}{\frac{1}{t!} e^{-n\theta} (n\theta)^t} = e^{-\theta} e^{\theta} \frac{(n-1)^t}{n^t} \quad (*)$$

$$\Pr(X_1=0) = e^{-\theta}$$

$$\Pr\left(\sum_{i=2}^n X_i = t\right) \sim \text{Poisson}((n-1)\theta)$$

$$\Pr\left(\sum_{i=1}^n X_i = t\right) \sim \text{Poisson}(n\theta)$$

$$\Rightarrow \left(\frac{n-1}{n}\right)^t = \left(\frac{n-1}{n}\right)^{\sum_{i=1}^n X_i} = H(S)$$

$$\Rightarrow \underline{H(S) \text{ ECMV para } h(\theta) = e^{-\theta}}$$

• Otra manera:

$$S = \sum_{i=1}^n X_i \text{ suficiente y completo}$$

$$E[H(S)] = h(\theta) = e^{-\theta}$$

$$H(S) \text{ ECMV para } h(\theta)$$

Lehmann-Scheffé

$$e^{-\theta} = E[H(S)] = \sum_{s=0}^{\infty} H(s) \frac{e^{-n\theta} (n\theta)^s}{s!}$$

$$S = \sum_{i=1}^n X_i \sim \text{Poisson}(n\theta)$$

$$e^{-\theta + n\theta} = \sum_{s=0}^{\infty} H(s) \frac{(n\theta)^s}{s!}$$

$$e^{\theta(n-1)} = \sum_{s=0}^{\infty} \frac{((n-1)\theta)^s}{s!}$$

$$\sum_{s=0}^{\infty} \frac{((n-1)\theta)^s}{s!} = \sum_{s=0}^{\infty} H(s) \frac{(n\theta)^s}{s!}$$

$$H(s) = \left(\frac{n-1}{n}\right)^s$$

Condiciones de regularidad de Fréchet-Cramer-Rao

- R1: El conjunto soporte de la distribución f_{θ} ,

$$S = \{ (x_1, \dots, x_n) \in X : f_{\theta}(x_1, \dots, x_n) > 0 \}$$

no depende de θ y que exista $\frac{\partial}{\partial \theta} f_{\theta}(x_1, \dots, x_n)$

- R2: Sea $h(\theta)$ función paramétrica de interés. $\forall T \in U_h$ debe cumplirse:

$$\left\{ \begin{array}{l} \frac{\partial}{\partial \theta} \int f_{\theta}(\vec{x}) d\vec{x} = \int \frac{\partial}{\partial \theta} f_{\theta}(\vec{x}) d\vec{x} \text{ en el caso continuo} \\ \frac{\partial}{\partial \theta} \sum_x f_{\theta}(\vec{x}) = \sum_x \frac{\partial}{\partial \theta} f_{\theta}(\vec{x}) \text{ en el caso discreto} \end{array} \right.$$

La condición de regularidad R2 es equivalente a:

$$E_{\theta} \left[\frac{\partial}{\partial \theta} \ln(f_{\theta}(\vec{x})) \right] = 0, \forall \theta \in \Theta$$

- Información de Fisher:

$$I_n(\theta) = E_{\theta} \left[\left(\frac{\partial}{\partial \theta} \ln(f_{\theta}(\vec{x})) \right)^2 \right]$$

- Teorema de las cotas de FCR:

Si se verifican las condiciones de regularidad R1 y R2 y sea $T \in U_h$

tal que
$$h'(\theta) = \frac{\partial E_{\theta}[T]}{\partial \theta} = \frac{\partial}{\partial \theta} \int T(\vec{x}) f_{\theta}(\vec{x}) d\vec{x} = \int T(\vec{x}) \frac{\partial}{\partial \theta} f_{\theta}(\vec{x}) d\vec{x}$$

$$I_n(\theta) = E_{\theta} \left[\left(\frac{\partial}{\partial \theta} \ln(f_{\theta}(\vec{x})) \right)^2 \right] \text{ que verifica } 0 < I_n(\theta) < \infty$$

Entonces

$$\frac{(h'(\theta))^2}{I_n(\theta)} \leq V_{\theta}[T], \forall \theta \in \Theta$$

Espero que
siempre sea
así

Además, COTA INFERIOR PARA LA VARIANZA DE TODOS LOS ESTIMADORES

CENTRADOS DE $h(\theta)$: (Si una de las estimadores centrados alcanza esta cota, es el CEFV para $h(\theta)$)

$$\frac{(h'(\theta))^2}{I_n(\theta)} = V_{\theta}[T], \forall \theta \in \Theta \iff \exists K(\theta) \text{ tal que}$$

$$\frac{\partial}{\partial \theta} \ln(f_{\theta}(\vec{x})) = K(\theta) [T(\vec{x}) - h(\theta)]$$

• COTA:
$$\frac{h'(\theta)}{K(\theta)}$$

Pedir eficiencia
en los
(posibles)

• Cálculo de la Información de Fisher:

1) $I_n(\theta) = n I_1(\theta)$

2) Si se verifican las condiciones de regularidad de Fisher:

$$\frac{\partial^2}{\partial \theta^2} \int_{\mathcal{X}} f_{\theta}(\vec{x}) d\vec{x} = \int \frac{\partial^2}{\partial \theta^2} f_{\theta}(\vec{x}) d\vec{x}$$

$$I_n(\theta) = -E_{\theta} \left[\frac{\partial^2}{\partial \theta^2} (\ln f_{\theta}(\vec{x})) \right]$$

• Observaciones importantes:

1) Si se verifican las condiciones de regularidad $R1$ y $R2$ y la adicional, entonces, si $\exists$ TELL cuya varianza alcance la cota de FCR, debe poder factorizarse

$$\frac{\partial}{\partial \theta} \ln f_{\theta}(\vec{x}) = \frac{n I_1(\theta) [T(\vec{x}) - h(\theta)]}{h'(\theta)}$$

$$k(\theta) = \frac{n I_1(\theta)}{h'(\theta)}$$

Si nos dan una exponencial está todo hecho

2) La expresión anterior permite construir el estimador T , la función $h(\theta)$ y el valor de la cota de FCR a menos de constantes ^{trasci} aditivas y multiplicativas.

Familia exponencial uniparamétrica

Si la familia de distribuciones de probabilidades verifica las condiciones de regularidad $R1$ y $R2$ y la cota es alcanzable, entonces la familia es exponencial uniparamétrica

$$f_{\theta}(\vec{x}) = c(\theta) h(\vec{x}) e^{\pi(\theta) T(\vec{x})}$$

T es el estadístico que alcanza la cota.

Recíprocamente, si la muestra se distribuye según la función de densidad anterior, con $\pi'(\theta)$ no nula, entonces T alcanza la cota de FCR

$$h'(\theta) = \frac{-c'(\theta)}{c(\theta)\pi'(\theta)}, \quad k(\theta) = \pi'(\theta)$$

• COTA FCR:

$$\frac{h'(\theta)}{\pi'(\theta)}$$

• Ejemplos:

1) m.a.s tamaño n Bernoulli(θ)

¿Cota FCR para $h(\theta) = \theta$?

$$P_{\theta}(x) = \theta^x (1-\theta)^{1-x}, \quad \theta \in (0,1)$$

$$P_{\theta}(\vec{x}) = \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i} = (1-\theta)^n e^{\left(\sum_{i=1}^n x_i \ln\left(\frac{\theta}{1-\theta}\right)\right)}$$

Familia exponencial
uniparamétrica

$$c(\theta) = (1-\theta)^n$$

$$T(\vec{x}) = \sum_{i=1}^n x_i$$

$$\eta(\theta) = \ln\left(\frac{\theta}{1-\theta}\right)$$

$$c'(\theta) = -n(1-\theta)^{n-1}$$

$$\eta'(\theta) = \frac{(\theta/(1-\theta))'}{\theta/(1-\theta)} = \frac{\frac{1(1-\theta) + \theta}{(1-\theta)^2}}{\frac{\theta}{1-\theta}} = \frac{(1-\theta)}{\theta(1-\theta)^2} = \frac{1}{\theta(1-\theta)}$$

$$h(\theta) = \frac{-c'(\theta)}{\eta'(\theta)}$$

$$h(\theta) = \frac{n(1-\theta)^{n-1}}{(1-\theta)^n \frac{1}{\theta(1-\theta)}} = \frac{n(1-\theta)^{n-1} \theta(1-\theta)}{(1-\theta)^n} = n\theta$$

$$\text{Cota: } \frac{h'(\theta)}{\eta'(\theta)} = n\theta(1-\theta) //$$

$\bar{x}$ alcanza la cota para $h(\theta) = \theta$

$\sum x_i$ alcanza la cota para $h(\theta) = n\theta$

• R_1, R_2 : (otra manera)

$$\ln P_{\theta}(\vec{x}) = \left(\sum_{i=1}^n x_i\right) \ln \theta + n \ln(1-\theta) - \left(\sum_{i=1}^n x_i\right) \ln(1-\theta)$$

$$\frac{\partial}{\partial \theta} \ln P_{\theta}(\vec{x}) = \frac{\sum_{i=1}^n x_i}{\theta} + n \left(\frac{-1}{1-\theta}\right) - \left(\sum_{i=1}^n x_i\right) \left(\frac{-1}{1-\theta}\right) = \frac{n\bar{x}}{\theta} - \frac{n}{1-\theta} + \frac{n\bar{x}}{1-\theta} =$$

$$= n\bar{x} \left(\frac{1}{\theta} + \frac{1}{1-\theta}\right) - \frac{n}{1-\theta} = n\bar{x} \left(\frac{1-\theta + \theta}{\theta(1-\theta)}\right) - \frac{n}{1-\theta} = \frac{n\bar{x}}{\theta(1-\theta)} - \frac{n}{1-\theta} =$$

$$= \left(\frac{n}{\theta(1-\theta)}\right) [\bar{x} - \theta]$$

$$k(\theta) [T(\vec{x}) - h(\theta)]$$

$$\text{Cota: } \frac{h'(\theta)}{k(\theta)} = \frac{1}{\frac{n}{\theta(1-\theta)}} = n\theta(1-\theta) //$$

• Otra manera: (Aplicando teorema de FCR)

$$\text{Cota: } \frac{(h'(\theta))^2}{I_n(\theta)}$$

$$h(\theta) = \theta$$

$$h'(\theta) = 1$$

$$I_n(\theta) = n I_1(\theta)$$

$$I_1(\theta) = -E_{\theta} \left[\frac{\partial^2}{\partial \theta^2} \ln f_{\theta}(x) \right]$$

$$P_\theta(x) = \theta^x (1-\theta)^{1-x}$$

$$\ln P_\theta(x) = x \ln \theta + (1-x) \ln (1-\theta)$$

$$\frac{\partial}{\partial \theta} \ln P_\theta(x) = \frac{x}{\theta} + (-1+x) \left(\frac{1}{1-\theta} \right)$$

$$\frac{\partial^2}{\partial \theta^2} \ln P_\theta(x) = -\frac{x}{\theta^2} + (x-1) \left(\frac{1}{(1-\theta)^2} \right)$$

$$\begin{aligned} I_1(\theta) &= -E_\theta \left[\frac{\partial^2}{\partial \theta^2} \ln P_\theta(x) \right] = \frac{1}{\theta^2} E[x] - \frac{1}{(1-\theta)^2} E[x-1] = \frac{1}{\theta^2} \theta - \frac{1}{(1-\theta)^2} (\theta-1) = \\ &= \frac{1}{\theta} + \frac{1}{1-\theta} = \frac{1}{\theta(1-\theta)} \end{aligned}$$

$$\Rightarrow \text{Cota: } \frac{(h'(\theta))^2}{n I_1(\theta)} = \frac{1}{\frac{n}{\theta(1-\theta)}} = n\theta(1-\theta)$$

2) $X_1, \dots, X_n$ m.a.s tamaño n de una población $X \sim \text{Uniforme}(0, 2\theta)$

Queremos estimar $h(\theta) = \theta$

$$f_\theta(x) = \frac{1}{2\theta}, \quad x \in (0, 2\theta)$$

(No cumple las condiciones de regularidad, luego no tiene sentido calcular la cota)

$$f_\theta(\vec{x}) = \left(\frac{1}{2\theta} \right)^n \prod_{i=1}^n I_{(0, 2\theta)}(x_i) = \frac{1}{(2\theta)^n} I_{(\frac{1}{2}x_{(n)}, \infty)}(\theta)$$



$$x_i \geq 0$$

$$x_{(n)} \leq 2\theta \Rightarrow x_{(n)} \in (-\infty, 2\theta)$$

$$2\theta \geq x_{(n)}$$

$$\theta \geq \frac{1}{2} x_{(n)} \Rightarrow \theta \in \left(\frac{1}{2} x_{(n)}, \infty \right)$$

$\Rightarrow X_{(n)}$ estadístico suficiente

Vemos que $X_{(n)}$ es también completo y, por el teorema de Basu sabemos que suficiente y completo $\Rightarrow$ minimal suficiente

$$E[X_{(n)}] = \int_0^{2\theta} \gamma n \left(\frac{\gamma}{2\theta} \right)^{n-1} d\gamma$$

$$F_{X_{(n)}}(\gamma) = (F(\gamma))^n = \left(\frac{\gamma}{2\theta} \right)^n$$

$$f(\gamma) = \frac{1}{2\theta}, \quad F(\gamma) = \int_0^\gamma \frac{1}{2\theta} d\gamma$$

$$f_{X_{(n)}}(\gamma) = n \left(\frac{\gamma}{2\theta} \right)^{n-1}$$

$$E[X_{(n)}] = \frac{n}{n+1} 2\theta \quad T_1(x_1, \dots, x_n) = \frac{n+1}{2n} x_{(n)}$$

Por L-S: ECMV H(T)
Único T suficiente y completo

$$E[T(x_1, \dots, x_n)] = \theta$$

$$T_2(x_1, \dots, x_n) = \bar{X}, \quad V(\bar{X}) = \dots$$

$$V\left(\frac{n+1}{2n} X_{(n)}\right) = \frac{(n+1)^2}{(2n)^2} E[X_{(n)}^2] - (E[X_{(n)}])^2$$

Tendremos que ver cuál es el de menor varianza.

3) $X_1, \dots, X_n$, Exponencial (θ) , $\theta > 0$

$$f_{\theta}(x) = \theta e^{-\theta x}$$

$$f_{\theta}(\vec{x}) = \theta^n e^{-\theta \sum_{i=1}^n x_i} = \theta^n e^{-n\theta \bar{x}}$$

$$c(\theta) = \theta^n$$

Familia exponencial uniparamétrica

$$\pi(\theta) = -n\theta$$

$$T(\vec{x}) = \bar{x}$$

$$c'(\theta) = n\theta^{n-1}$$

$$\pi'(\theta) = -n$$

$T(X_1, \dots, X_n)$ es el estadístico que alcanza la cota para

$$h(\theta) = \frac{-c'(\theta)}{c(\theta)\pi'(\theta)} = \frac{-n\theta^{n-1}}{\theta^n(-n)} = \frac{1}{\theta}$$

$$\text{Cota: } \frac{h'(\theta)}{\pi'(\theta)} = \frac{-\frac{1}{\theta^2}}{-n} = \frac{1}{n\theta^2} //$$

• Otra manera:

$$\ln f_{\theta}(\vec{x}) = n \ln \theta - n\bar{x}\theta$$

$$\frac{\partial}{\partial \theta} \ln f_{\theta}(\vec{x}) = \frac{n}{\theta} - n\bar{x} = -n \left[\bar{x} - \frac{1}{\theta} \right]$$

$$\text{Cota: } \frac{h'(\theta)}{\pi'(\theta)} = \frac{-\frac{1}{\theta^2}}{-n} = \frac{1}{n\theta^2} //$$

• Estimar $h(\theta) = \theta$:

$\bar{X}$ es suficiente

$$\text{Además, } \bar{X} \text{ es completo: } \begin{array}{ccc} \theta & \xrightarrow{\pi} & \mathbb{R}^1 \\ \theta & \xrightarrow{\pi} & -n\theta \\ \theta \geq 0 & & \end{array}$$

Podemos elegir un intervalo

$$E[\bar{X}] = \frac{1}{\theta}$$

$$E[H(\bar{X})] = \theta$$

$$T = \sum X_i \sim \text{Gamma}(\theta, n)$$

$$\theta = E_{\theta}[H(T)] = \int_0^{\infty} H(T) \frac{\theta^n}{\Gamma(n)} e^{-\theta t} t^{n-1} dt$$

$$\frac{(n-1)\Gamma(n-1)}{\theta^{n-1}} = \frac{\theta}{\theta^n} \Gamma(n) = \int_0^{\infty} H(t) e^{-\theta t} t^{n-1} dt$$

$$\int_0^{\infty} e^{-\theta t} t^{n-1} dt = \frac{\Gamma(n-1)}{\theta^{n-1}} \quad (\text{lo sabemos por la fórmula})$$

$$(n-1) \int_0^{\infty} e^{-\theta t} t^{n-2} dt = \int_0^{\infty} H(t) e^{-\theta t} t^{n-1} dt$$

$$H(t) = t^{-1}(n-1) = \frac{n-1}{t}$$

$$\Rightarrow \boxed{H(t) = \frac{n-1}{\sum_{i=1}^n X_i}} \quad \text{ECMV para } h(\theta) = \theta$$

• Si nos piden calcular la cota:

$$\text{Cota: } \frac{(h'(\theta))^2}{I_n(\theta)}$$

$$\text{Cota: } \frac{\sigma^2}{n}$$

$$I_n(\theta) = n I_1(\theta)$$

$$I_1(\theta) = -E\left[\frac{\partial^2}{\partial \theta^2} \ln f(x)\right]$$

• NOTA:

• Sabemos que $\bar{X}, \sum X_i$ alcanza la cota para $h(\theta) = \frac{1}{\theta}$, y si este la alcanza no puede haber otro que alcance la cota para otra $h(\theta)$, salvo constantes multiplicativas, luego $V(\sum X_i)$ no puede alcanzar la cota para $h(\theta) = \theta$.

$$\text{Calculamos } V\left(\frac{n-1}{\sum X_i}\right):$$

$$X_i \sim \text{Exp}(\theta) = \text{gamma}(\theta, 1)$$

$$\sum_{i=1}^n X_i \sim \text{gamma}(\theta, n)$$

$$Y = \frac{n-1}{\sum_{i=1}^n X_i}$$

$$t \xrightarrow{\theta} \frac{n-1}{t} = Y$$

$$t = \frac{n-1}{Y} \xrightarrow{\theta} \frac{n-1}{Y}$$

$$\left| \frac{\partial t}{\partial Y} \right| = \left| \frac{n-1}{Y^2} \right|$$

$$f_Y(y) = f_X\left(\frac{n-1}{y}\right) \left(\frac{n-1}{y^2}\right) = \frac{\theta^n}{\Gamma(n)} e^{-\theta \frac{n-1}{y}} (n-1)^n y^{-(n+1)}$$

$$E_\theta[Y] = \frac{\theta^n}{\Gamma(n)} (n-1)^n \int_0^\infty e^{-\theta \frac{n-1}{y}} y^n dy = \frac{\theta^n}{\Gamma(n)} (n-1)^n \int_0^\infty e^{-\theta(n-1)x} x^{n-2} dx \quad (*)$$

$$x = \frac{1}{y} \rightarrow dx = -\frac{1}{y^2} dy$$

$$a = \theta(n-1)$$

$$y = \frac{1}{x} \rightarrow dy = -\frac{1}{x^2} dx = -\frac{1}{x^2} dx$$

$$p-1 = n-2 \Rightarrow p = n-1$$

$$y=0 \rightarrow x = \infty$$

$$\frac{\Gamma(p)}{a^p} = \frac{\Gamma(n-1)}{(\theta(n-1))^p}$$

$$y=\infty \rightarrow x=0$$

$$\stackrel{(*)}{=} \frac{\theta^n}{\Gamma(n)} (n-1)^n \frac{\Gamma(n-1)}{(n-1)^{n-1} \theta^{n-1}} = \frac{\Gamma(n-1) (n-1)}{(n-1) \Gamma(n-1) \theta} = \theta$$

$$E[Y^2] = \frac{\theta^n}{\Gamma(n)} (n-1)^n \int_0^{\infty} e^{-\theta(n-1)x} x^{n-3} dx = \frac{\theta^2 (n-1)}{n-2}$$

$$a = \theta(n-1)$$

$$p-1 = n-3 \Rightarrow p = n-2$$

$$\frac{\Gamma(n-2)}{(\theta(n-1))^{n-2}}$$

$$V(Y) = E[Y^2] - (E[Y])^2 = \frac{\theta^2}{n-2}$$

$$\bullet \text{Cota: } \frac{(h(\theta))^2}{I_n(\theta)} = \frac{\theta^2}{n}$$

MÉTODOS DE OBTENCIÓN DE ESTIMADORES

1. M Momentos

$$\theta = (\theta_1, \dots, \theta_r)$$

$$\alpha_k = E[X^k] = \alpha_k(\theta_1, \dots, \theta_r)$$

$$\alpha_k(\theta_1, \dots, \theta_r) = \alpha_k, \quad k=1, \dots, r$$

$$\hat{\theta}_1(x_1, \dots, x_n), \dots, \hat{\theta}_r(x_1, \dots, x_n)$$

Ejemplos:

$$1) X \sim N(\mu, \sigma^2), \quad \theta = (\mu, \sigma^2)$$

$$x_1, \dots, x_n \quad r=2$$

$$\alpha_1 = E[X] = \mu = a_1 = \bar{X}$$

$$\alpha_2 = E[X^2] = V(X) + (E[X])^2 = \sigma^2 + \mu^2$$

$$\begin{cases} \mu = \alpha_1 \\ \sigma^2 = \alpha_2 - \alpha_1^2 \end{cases}$$

$$\begin{aligned} (\alpha_1, \alpha_2) &\xrightarrow{g} (\alpha_1, \alpha_2 - \alpha_1^2) \\ (a_1, a_2) &\xrightarrow{g} (a_1, a_2 - a_1^2) \end{aligned}$$

$$T_1 = a_1 = \bar{X}, \quad T_2 = a_2 - a_1^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

$$2) X \sim B(n, \theta) \quad n \in \mathbb{N}, \quad \theta = (n, \theta)$$

$$x_1, \dots, x_n \quad r=2$$

$$\alpha_1 = E[X] = n\theta$$

$$\alpha_2 = E[X^2] = V(X) + (E[X])^2 = n\theta(1-\theta) + n^2\theta^2$$

$$n = \alpha_1/\theta$$

$$\alpha_2 = \alpha_1/\theta \theta(1-\theta) + n^2\theta^2 \Rightarrow \theta = \frac{\alpha_1^2 + \alpha_1 - \alpha_2}{\alpha_1} //$$

$$(\alpha_1, \alpha_2) \xrightarrow{\delta} \left(\frac{\alpha_1^2}{\alpha_1^2 + \alpha_1 - \alpha_2}, \frac{\alpha_1^2 + \alpha_1 - \alpha_2}{\alpha_1} \right)$$

$$(\alpha_1, \alpha_2) \longrightarrow \begin{matrix} T(\bar{X}) \\ \hat{\theta}(x) \end{matrix} = \left(\frac{\alpha_1^2}{\alpha_1^2 + \alpha_1 - \alpha_2}, \frac{\alpha_1^2 + \alpha_1 - \alpha_2}{\alpha_1} \right)$$

$$3) X, \quad P(X=x) = \begin{cases} \frac{1}{2}(1-\theta) & x=-1 \\ \frac{1}{2} & x=0 \\ \frac{1}{2}\theta & x=1 \end{cases}$$

¿Estimador de θ M.M.? ¿Estimador centrado? ¿Estimador consistente?

$$r=1$$

$$\bullet \alpha_1 = E[X] = \sum X_i P(X=x_i) = -1 \cdot \frac{1}{2}(1-\theta) + 0 \cdot \frac{1}{2} + \frac{1}{2}\theta = -\frac{1}{2} + \theta \Rightarrow \theta = \alpha_1 + \frac{1}{2} //$$

$$\alpha_1 \xrightarrow{\delta} \left(\alpha_1 + \frac{1}{2} \right)$$

$$\alpha_1 \longrightarrow \alpha_1 + \frac{1}{2} = \bar{X} + \frac{1}{2}$$

$$\bullet E[\bar{X} + \frac{1}{2}] = E[\bar{X}] + \frac{1}{2} = \frac{1}{n} n E[X_i] + \frac{1}{2} = \theta - \frac{1}{2} + \frac{1}{2} = \theta // \quad (\text{Centrado})$$

$$\bullet \lim_{n \rightarrow \infty} E[T] = h(\theta)$$

$$\lim_{n \rightarrow \infty} V[T] = 0$$

$$V(\bar{X} + \frac{1}{2}) = V(\bar{X}) = \frac{1}{n^2} n V(X_i) = \frac{1}{n} \left[\frac{1}{2} - \theta^2 + \theta \right] \longrightarrow 0 // \quad (\text{Consistente})$$

$$E[X_i^2] = \frac{1}{2}(1-\theta) + 0 \cdot \frac{1}{2} + \frac{1}{2}\theta = \frac{1}{2}$$

$$V(X_i) = E[X_i^2] - (E[X_i])^2 = \frac{1}{2} - \theta^2 + \theta$$

• Propiedades de los estimadores obtenidos por MM:

(1) Son centrados.

(2) Son consistentes: $\{\alpha_k\} \xrightarrow{p} \alpha_k \quad \text{LDGR}$

(3) T.C.L: Normalidad asintótica:

$$\alpha_k \longrightarrow N\left(\alpha_k, \frac{V[X_k]}{n}\right)$$

2. Método de máxima similitud (EMV)

$$f(\vec{x}|\theta) = f_{\theta}(\vec{x}) = f_{\theta}(x_1, \dots, x_n) = L(\theta|\vec{x}) = L_{\vec{x}}(\theta) \quad \text{función de verosimilitud}$$

El método de máxima similitud consiste en elegir como estimador del parámetro θ (desconocido) aquel valor $T(x_1, \dots, x_n)$ que hace máxima la función de verosimilitud:

$$\hat{\theta}(x_1, \dots, x_n), \quad L(\hat{\theta}|\vec{x}) = \max_{\theta \in \Theta} L(\theta|x_1, \dots, x_n)$$

$$\max_{\theta \in \Theta} \ln L(\theta|x_1, \dots, x_n)$$

$$\frac{\partial}{\partial \theta} \ln(L(\theta|x_1, \dots, x_n)) \rightarrow \hat{\theta}(x_1, \dots, x_n)$$

• Ejemplos:

1) $X \sim N(\theta, 1)$

$x_1, \dots, x_n$ m.a.s
EMV?

$$f_{\theta}(\vec{x}) = L_{\vec{x}}(\theta) = \frac{1}{(2\pi)^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n (x_i - \theta)^2}$$

$$\ln L_{\vec{x}}(\theta) = -\frac{n}{2} \ln(2\pi) - \frac{1}{2} \sum_{i=1}^n (x_i - \theta)^2$$

$$\frac{\partial}{\partial \theta} \ln L_{\vec{x}}(\theta) = \frac{1}{2} \sum_{i=1}^n (2(x_i - \theta)) = n\bar{x} - n\theta = 0$$

$$\frac{\partial^2}{\partial \theta^2} \ln L_{\vec{x}}(\theta) = -n < 0 \Rightarrow \hat{\theta} = \bar{x} \quad \begin{matrix} \downarrow \\ \bar{x} = \theta \end{matrix} \quad \begin{matrix} T(x_1, \dots, x_n) \\ \theta(x_1, \dots, x_n) \end{matrix}$$


Máximo relativo

Estudicamos la frontera para ver si es absoluta:

$$\lim_{\theta \rightarrow \pm \infty} L_{\vec{x}}(\theta) = 0$$

$$x_i \in \mathbb{R}$$

$$\hat{\theta} = \bar{x} \text{ es un máximo global} \Rightarrow \boxed{\bar{x} \text{ es EMV}}$$



$$\bar{x} \geq 0, \quad 0 \text{ es EMV}$$

$$\bar{x} \leq 0$$

3) $X \sim B(1, \theta)$

$X_1, \dots, X_n$
EMV?

$$f_{\vec{x}}(\vec{x}) = L_{\vec{x}}(\theta) = \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i}$$

$$\ln L_{\vec{x}}(\theta) = \left(\sum_{i=1}^n x_i\right) \ln \theta + \left(n - \sum_{i=1}^n x_i\right) \ln(1-\theta)$$

$$\frac{\partial}{\partial \theta} \ln L_{\vec{x}}(\theta) = \frac{\left(\sum_{i=1}^n x_i\right)}{\theta} - \frac{\left(n - \sum_{i=1}^n x_i\right)}{1-\theta} = 0 \Rightarrow \frac{\sum_{i=1}^n x_i}{\theta} + \frac{\sum_{i=1}^n x_i}{1-\theta} - \frac{n}{1-\theta} = 0$$

De modo que

$$0 = \frac{n\bar{x}}{\theta} + \frac{n\bar{x}}{1-\theta} - \frac{n}{1-\theta} = \frac{n\bar{x} - n\bar{x}\theta + n\bar{x}\theta - n\theta}{\theta(1-\theta)} = \frac{n(\bar{x} - \theta)}{\theta(1-\theta)}$$

$$\boxed{\bar{x} = \hat{\theta}}$$

Falta ver que es máximo absoluto:


$$\theta \in [0, 1]$$

$$L_{\vec{x}}(\theta=0) = 0 \in [0, 1]$$

$$L_{\vec{x}}(\theta=1) = 0 \in [0, 1]$$

$$\boxed{\bar{x} \text{ es EMV para } \theta}$$


• $\theta \in (0, 1)$



$\bar{x} > \theta$ creciente
 $\bar{x} < \theta$ decreciente

Si $\bar{x} = 0$ $\nexists$ EMV


• $\theta \in [\frac{1}{4}, \frac{3}{4}]$



$$\bar{x} < \frac{1}{4}$$

$$\frac{1}{4} \leq \bar{x} \leq \frac{3}{4}$$

$$\bar{x} \geq \frac{3}{4}$$



4) $X \sim U(0, \theta)$, $\theta \geq 0$

$X_1, \dots, X_n$

$$L_{\vec{x}}(\theta) = \frac{1}{\theta^n} \prod_{i=1}^n I_{[0, \theta]}(x_i)$$

$$\ln L_{\vec{x}}(\theta) = -n \ln \theta$$

$$\frac{\partial}{\partial \theta} \ln L_{\vec{x}}(\theta) = -\frac{n}{\theta} = 0 \Rightarrow -n = 0 \text{ ¡!}$$


Como es en uniforme recordamos

$$L_{\vec{x}}(\theta) = \frac{1}{\theta^n} \prod_{i=1}^n I_{[0, \theta]}(x_i) = \frac{1}{\theta^n} I_{[x_{(n)}, \infty)}(\theta)$$

Como el máximo depende de θ y $\theta \in (x_{(n)}, \infty)$, el máximo estará

5) $X \sim U(\theta - \frac{1}{2}, \theta + \frac{1}{2})$
 $x_1, \dots, x_n$
 EMV?

$$L(\hat{\theta}) = \prod_{i=1}^n I_{(\theta - \frac{1}{2}, \theta + \frac{1}{2})}(x_i) = I_{[x_{(n)} - \frac{1}{2}, x_{(1)} + \frac{1}{2}]}(\hat{\theta})$$



El EMV es cualquier punto del intervalo $[x_{(n)} - \frac{1}{2}, x_{(1)} + \frac{1}{2}]$

$$\rightarrow \theta - \frac{1}{2} \leq x_{(n)}$$

$$\theta \leq x_{(n)} + \frac{1}{2}$$

$$\theta \in (-\infty, x_{(n)} + \frac{1}{2}]$$

$$\rightarrow x_{(1)} \leq \theta + \frac{1}{2}$$

$$x_{(1)} - \frac{1}{2} \leq \theta$$

$$\theta \in [x_{(1)} - \frac{1}{2}, \infty)$$

6) Tenemos 4 bolas y sacamos 2 bolas con reemplazamiento, sabiendo que mínimo hay 1B y 1N.

x_1	x_2
B	B
B	N_1
B	N_2
B	N_3
N_1	B
N_1	N_1
...	...

B	N_1	N_2	N_3
$\theta = \frac{1}{4}$			P
$x=0$ (2 negras)			$\frac{9}{16}$
$x=1$ (B1N)			$\frac{6}{16}$
$x=2$ (2 blancas)			$\frac{1}{16}$

• Hagámoslo ahora con 2 blancas y 2 negras:

$x \backslash \theta$	$\theta = 1/4$	$\theta = 1/2$	$\theta = 3/4$
$x=0$	$9/16$	$4/16$	$1/16$
$x=1$	$6/16$	$8/16$	$6/16$
$x=2$	$1/16$	$4/16$	$9/16$

$\uparrow$
1B y 3N

$\uparrow$
3B y 1N

• Propiedades de los EMV:

1) Suficiencia:

Si $\hat{\theta}$ es un estimador suficiente y el EMV existe y es único, es función del estimador suficiente:

• Demostración:

$$\hat{\theta} = T(x_1, \dots, x_n) \xRightarrow{T_{\text{fact.}}} f_{\theta}(\vec{x}) = h(x) g_{\theta}(\hat{\theta})$$

El EMV existe y es único, maximiza

$$g_{\theta}(\hat{\theta}) \Rightarrow \text{Será función de } \hat{\theta}$$

2) Consistentes: (En condiciones bastante generales)

Es decir, que el dominio no esté acotado por el parámetro, que se cumplan R_1 y R_2 .

3) Centralidad:

No son centrados, pero sí son asintóticamente centrados.

$$\begin{array}{ccc} \hat{\theta}_n & \xrightarrow{P} & \theta \\ \sigma_n & \longrightarrow & E[\hat{\theta}] \end{array} \quad \text{L.D.G.N}$$

4) Eficiencia: (Cond. regularidad)

El estimador eficiente, si existe, es el EMV.

5) Invarianza:

Los estimadores son invariantes frente a transformaciones

$$\hat{\theta} \text{ EMV para } \theta$$

$$g \text{ función de inversa única} \Rightarrow g(\hat{\theta}) \text{ es EMV para } g(\theta)$$

ESTADÍSTICA BAYESIANA

En la estadística bayesiana θ es una v.a. (tiene una distribución y será con la que trabajemos).

- Ejemplo: Lanzar una moneda al aire

$P(\text{cara})$ éxito Bernoulli(θ)
 $P(\text{cruz})$ fracaso

$$\theta = 1/2$$

$$\left. \begin{array}{l} \text{Tiro 1 vez} = \begin{array}{c} \text{C} \\ \text{C} \\ \text{C} \\ \text{X} \\ \vdots \\ 100 \\ \vdots \\ \infty \end{array} \end{array} \right\} P(\text{éxito}) = \frac{n_E}{n_{\text{total}}} = \frac{n_E}{n}$$

$\xleftarrow{\text{frecuencia}} \quad \xrightarrow{\text{límite}}$

- La estadística que usamos se basa en la frecuencia relativa. (básica)
- La estadística bayesiana se basa en la creencia subjetiva sobre θ .

- Cojo otra vez este experimento:

Tiro la moneda θ , θ v.a.

$$P(\text{cara}) = \frac{1}{2}$$

Si θ es v.a., tiene una distribución: "se distribuye de alguna manera basada en mi experiencia"

La realización concreta con los muestros (números) hará que tenga una distribución final de θ que ha cambiado por $x_1, \dots, x_n$ (muestra). Esto se hace con el teorema de Bayes.

- Teorema de Bayes:

B, A dos sucesos elementales

$$Pr(B|A) = \frac{Pr(A|B) \cdot Pr(B)}{Pr(A)} = \frac{Pr(A|B) \cdot Pr(B)}{\sum_{B_i} Pr(A|B_i) \cdot Pr(B_i)}$$

considerando $Pr(A)$ pr marginal

$$f(\theta|x_1, \dots, x_n) = \frac{f(x_1, \dots, x_n|\theta) f(\theta)}{\int_{\theta \in \Theta} f(x_1, \dots, x_n|\theta) f(\theta) d\theta}$$

$f(x_1, \dots, x_n|\theta)$ función de densidad conjunta de los muestros

$f(\theta) = \pi(\theta) \Rightarrow \pi(\theta)$ distribución a priori de θ (lo que yo quiero)

$\pi(\theta|x_1, \dots, x_n)$ distribución final o a posteriori de θ

$\pi(\theta|x_1, \dots, x_n)$ o bien una medida de centralización de los

Familia conjugada

$$P_1 = \{ \pi(\theta) : \vec{\alpha} \in A \} \quad \text{o v.m., } \vec{\alpha} \text{ parámetros}$$

Esta familia es conjugada de la familia de funciones de densidad de la población.

→ π final tiene que ser $\in P_1$, $\pi(\theta | x_1, \dots, x_n) \vec{\alpha} \in A$?

$$P_2 = \{ f(\vec{x} | \theta); \theta \in \Theta \}$$

• Casos:

1) $\theta \sim \pi(\theta)$ Beta

$f(\vec{x} | \theta)$ población Bernoulli, binomial o binomial negativa
más frecuentes

⇒ familia conjugada ⇒ $\pi(\theta | x_1, \dots, x_n)$ Beta

2) $\theta \sim \pi(\theta)$ Gamma

$f(\vec{x} | \theta)$ población Poisson o exponencial

⇒ familia conjugada ⇒ distribución final $\pi(\theta | x_1, \dots, x_n)$ Gamma

3) $\theta \sim \pi(\theta)$ Normal (μ_0, σ_0^2)

$f(\vec{x} | \theta)$ población Normal (μ, σ^2), σ^2 conocido

⇒ familia conjugada ⇒ $\pi(\theta | x_1, \dots, x_n)$ Normal

• Ejemplos:

1) $X \sim \text{Binomial}(n, \theta)$

$x_1, \dots, x_n$ muestra de tamaño n (m.i.a.s.)

A priori: $\theta \sim \pi(\theta) = \text{Beta}(p, q)$

Demstrar que es una Beta y obtener los parámetros.

La distribución final viene dada por Bayes:

$$\pi(\theta | x_1, \dots, x_n) = \frac{f(x_1, \dots, x_n | \theta) \pi(\theta)}{\int_{\theta \in \Theta} f(x_1, \dots, x_n | \theta) \pi(\theta) d\theta} \quad (*) \quad (\text{lo que no depende de } \theta \text{ se cancela})$$

$$\pi(\theta) = \frac{1}{\beta(p, q)} \theta^{p-1} (1-\theta)^{q-1}, \quad \theta \in (0, 1)$$

Función de densidad conjunta de la muestra:

$$f(x_1, \dots, x_n | \theta) = \prod_{i=1}^n \binom{n}{x_i} \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i}$$

$$\begin{aligned}
 \textcircled{*} &= \frac{\frac{1}{\beta(p,q)} \theta^{p-1} (1-\theta)^{q-1} \prod_{i=1}^n \binom{x_i}{x_i} \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n-\sum_{i=1}^n x_i}}{\int_0^1 \frac{1}{\beta(p,q)} \theta^{p-1} (1-\theta)^{q-1} \prod_{i=1}^n \binom{x_i}{x_i} \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n-\sum_{i=1}^n x_i} d\theta} \\
 &= \frac{\theta^{p-1+\sum_{i=1}^n x_i} (1-\theta)^{q-1+n-\sum_{i=1}^n x_i}}{\int_0^1 \theta^{p-1+\sum_{i=1}^n x_i} (1-\theta)^{q-1+n-\sum_{i=1}^n x_i} d\theta} = \frac{\theta^{(a-1)} (1-\theta)^{(b-1)}}{\int_0^1 \theta^{(a-1)} (1-\theta)^{(b-1)} d\theta} = \frac{\theta^{(a-1)} (1-\theta)^{(b-1)}}{\beta(a,b)} \\
 &= \text{Beta}(a,b) = \pi(\theta | x_1, \dots, x_n) \\
 &\quad \boxed{a = p + \sum x_i} \\
 &\quad \boxed{b = q + n - \sum x_i}
 \end{aligned}$$

$a-1 = p-1 + \sum x_i \Rightarrow a = p + \sum x_i$
 $b-1 = q-1 + n - \sum x_i \Rightarrow b = q + n - \sum x_i$

2) $X \sim \text{Poisson}(\theta), \theta > 0$
 $x_1, \dots, x_n$ m.a.s tamaño n

$\theta \sim \pi(\theta) = \text{Gamma}(p, q)$

Obtener distribución final.

$$\pi(\theta) = \frac{p^q}{\Gamma(q)} e^{-p\theta} \theta^{q-1}$$

$$f(x_1, \dots, x_n) = \frac{e^{-n\theta} \theta^{\sum x_i}}{\prod x_i!}$$

$$\begin{aligned}
 \pi(\theta | \vec{x}) &= \frac{f(x_1, \dots, x_n | \theta) \pi(\theta)}{\int_0^\infty f(x_1, \dots, x_n | \theta) \pi(\theta) d\theta} = \frac{e^{-p\theta} \theta^{q-1} e^{-n\theta} \theta^{\sum x_i}}{\int_0^\infty e^{-(n+p)\theta} \theta^{q-1+\sum x_i} d\theta} = \frac{e^{-(n+p)\theta} \theta^{q-1+\sum x_i}}{\frac{\Gamma(b)}{a^b}} \\
 &= \frac{a^b}{\Gamma(b)} e^{-a\theta} \theta^{b-1} \\
 &\quad \text{Distribución Gamma}(a,b)
 \end{aligned}$$

$a = n+p$
 $b-1 = q-1 + \sum x_i \Rightarrow b = q + \sum x_i$
 $\int_0^\infty e^{-a\theta} \theta^{b-1} d\theta = \frac{\Gamma(b)}{a^b}$

$a = n+p$
 $b = q + \sum x_i$

3) $X \sim N(\theta, \sigma^2)$ $\theta = \mu$
 $x_1, \dots, x_n$ σ^2 conocido

$\theta \sim \pi(\theta) = N(\mu_0, \sigma^2)$

$$\pi(\mu | \vec{x}) = \frac{f_0(\vec{x}) \pi(\theta)}{\int_{-\infty}^{\infty} f_0(\vec{x}) \pi(\theta) d\theta}$$

$$f_0(\vec{x}) \pi(\theta) = e^{-\frac{1}{2\sigma^2} \sum (x_i - \mu)^2 - \frac{1}{2\sigma^2} (\mu - \mu_0)^2} = \textcircled{*}$$

$$\sum (x_i - \mu)^2 = \sum (x_i - \bar{x} + \bar{x} - \mu)^2 = \sum x_i^2 + n\bar{x}^2 - 2n\bar{x}\mu$$

$$(\mu - \mu_0)^2 = \mu^2 + \mu_0^2 - 2\mu\mu_0$$

$$\textcircled{*} = -\frac{1}{2} \left[\frac{(\sum x_i^2 + n\bar{x}^2 - 2n\bar{x}\mu)\sigma^2}{\sigma^2} + \frac{(\mu^2 + \mu_0^2 - 2\mu\mu_0)\sigma^2}{\sigma^2} \right] =$$

$$= -\frac{1}{2} \left[\mu^2 - 2\mu \left(\frac{n\bar{x}\sigma_0^2 + n_0\sigma^2}{n\sigma_0^2 + \sigma^2} \right) + A \right] =$$

Constantes que no dependen de μ
(se nos cancelan)

Suma y resta B^2

$$B = \frac{n\bar{x}\sigma_0^2 + n_0\sigma^2}{n\sigma_0^2 + \sigma^2}$$

$$= -\frac{1}{2} \left[\frac{(\mu - B)^2}{\frac{\sigma_0^2 \sigma^2}{n\sigma_0^2 + \sigma^2}} + C \right]$$

Constantes que no dependen de μ

$$\pi(\theta|\vec{x}) = \frac{\int \vec{x} \pi(\theta) d\theta}{\int \vec{x} \pi(\theta) d\theta} = \frac{e^{-\frac{1}{2} \left[\frac{(\mu - B)^2}{D} \right]}}{\int_{-\infty}^{\infty} e^{-\frac{1}{2} \left[\frac{(\mu - B)^2}{D} \right]} d\mu} = \frac{e^{-\frac{1}{2} \left[\frac{(\mu - B)^2}{D} \right]}}{\sqrt{2\pi} \sqrt{D}} \sim N(B, D)$$

Media: B
Varianza: D

$$\text{Llamemos } B = \mu_x = \frac{n_0\sigma^2 + n\bar{x}\sigma_0^2}{n\sigma_0^2 + \sigma^2} = \frac{\frac{n_0}{\sigma_0^2} + \bar{x}\frac{n}{\sigma^2}}{\frac{n\sigma^2 + \sigma_0^2}{\sigma_0^2 \sigma^2}} = \frac{\frac{n_0}{\sigma_0^2} + \bar{x}\left(\frac{n}{\sigma^2}\right)}{\frac{1}{\sigma_0^2} + \left(\frac{n}{\sigma^2}\right)}$$

(No memorizar)

$$D = \sigma_x^2 = \frac{\sigma^2 \sigma_0^2}{n\sigma_0^2 + \sigma^2} = \frac{1}{\frac{n\sigma_0^2 + \sigma^2}{\sigma^2 \sigma_0^2}} = \frac{1}{\frac{1}{\sigma_0^2} + \left(\frac{n}{\sigma^2}\right)}$$

Memorizar

Definición de función pérdida:

Es una función $L: \Theta \times \Theta \rightarrow \mathbb{R}$ tal que

a) $L(\theta, \hat{\theta}) \geq 0, \forall \theta, \hat{\theta} \in \Theta$

θ v. a. $\pi(\theta|\vec{x}), \hat{\theta} = \mu_x$

b) $L(\theta, \hat{\theta}) = 0$ si $\theta = \hat{\theta}$

c) $L(\theta, \hat{\theta}_1) \leq L(\theta, \hat{\theta}_2)$

Ejemplos:

$\rightarrow L(\theta, \hat{\theta}) = |\theta - \hat{\theta}|$ ERROR ABSOLUTO DE LA ESTIMACIÓN

$\rightarrow L(\theta, \hat{\theta}) = (\theta - \hat{\theta})^2$ FUNCIÓN PÉRDIDA CUADRÁTICA

Riesgo de un estimador o pérdida final:

$$R(\theta, \hat{\theta}) = E[L(\theta, \hat{\theta})] = \int_{\Theta} L(\theta, \hat{\theta}) \pi(\theta|\vec{x}) d\theta$$

El estimador óptimo θ^* es el que minimiza la función pérdida final

Ejemplo:

Si nuestra función pérdida es la función pérdida cuadrática, entonces $R(\theta, \hat{\theta}) = E[(\theta - \hat{\theta})^2]$

• Teorema:

Si la función pérdida es cuadrática, el estimador bayesiano es la esperanza de la distribución a posteriori.

• Demostración:

$$\theta^* = E[\pi(\theta|\vec{x})]$$

$$\begin{aligned} R(\theta, \hat{\theta}) &= E[(\theta - \hat{\theta})^2 | \vec{x}] = E[(\theta - \theta^* + \theta^* - \hat{\theta})^2] = \int (\theta - \hat{\theta})^2 + (\theta^* - \hat{\theta})^2 \\ &= \int_{\theta} [(\theta - \theta^*)^2 + (\theta^* - \hat{\theta})^2 + \underbrace{2(\theta - \theta^*)(\theta^* - \hat{\theta})}] \pi(\theta|\vec{x}) d\theta = \\ &= V(\theta) + (\theta^* - \hat{\theta})^2 \quad \quad \quad 2(\hat{\theta} - \theta^*) \int (\theta - \theta^*) \pi(\theta|\vec{x}) d\theta = 0 = \\ &= 2(\hat{\theta} - \theta^*) \underbrace{\left[\int_{\theta} \theta \pi(\theta|\vec{x}) d\theta \right]}_{\theta^*} - \theta^* \int_{\theta} \pi(\theta|\vec{x}) d\theta \\ &= 2(\hat{\theta} - \theta^*) \theta^* - \theta^* = 0 \end{aligned}$$

$$\hat{\theta} = \theta^* = E[\pi(\theta|\vec{x})]$$

$$R(\theta, \hat{\theta}) = V(\theta)$$

Intervalos creíbles

θ v.a., $\theta \sim \pi(\theta|\vec{x})$

$\hat{\theta}$ estadístico bayesiano

$\theta \in [\theta_1(x_1, \dots, x_n), \theta_2(x_1, \dots, x_n)]$

Fijo $\alpha \in (0, 1)$:

$$Pr(\theta_1(x_1, \dots, x_n) \leq \theta \leq \theta_2(x_1, \dots, x_n)) = 1 - \alpha$$

$\pi(\theta|\vec{x})$

← Intervalo creíble con grado $1 - \alpha$ (si estamos en densidad 1)

PROBLEMAS TEMA 4. PARTE 1

1. Para una m.a.s de tamaño n de una población Bernoulli(θ), encontrar un estimador centrado de $h(\theta) = \theta^2$.

Sabemos que un estimador T es centrado si $E[T(\vec{X})] = h(\theta) = \theta^2$

Estamos ante una población Bernoulli(θ); luego $f(x) = \theta^x(1-\theta)^{1-x}$, con $x=0,1$

$$P(X=0) = \theta^0(1-\theta)^1 = 1-\theta$$

$$P(X=1) = \theta^1(1-\theta)^0 = \theta$$

$$\text{Sea } W = \begin{cases} 1 & \text{si } X_1 \cdot X_2 = 1 \text{ (pruebas con } X_1, X_2, X_3, X_4, \dots) \\ 0 & \text{otro caso} \end{cases}$$

$$P(W=1) = P(X_1, X_2=1) = \theta^2 \quad (P(X_1=1) \cdot P(X_2=1))$$

$$\rightarrow E[W] = 1 \cdot P(X_1, X_2) + 0 \cdot P(\text{resto}) = \theta^2$$

Entonces $E[W] = \theta^2$, luego $T(X_1, \dots, X_n) = X_1 \cdot X_2$ es un estimador centrado para $h(\theta) = \theta^2$.

3. Para una m.a.s de tamaño n de una población $U(\theta - \frac{1}{2}, \theta + \frac{1}{2})$, estudiar si el estimador $T(\vec{X}) = X_{(n)} - X_{(1)}$ es centrado para $h(\theta) = \theta$.

$$f(x) = \frac{1}{\theta + \frac{1}{2} - \theta - \frac{1}{2}} = 1 \Rightarrow F(x) = \int_{\theta - \frac{1}{2}}^x 1 \, dx = x - \theta + \frac{1}{2}$$

$$\bullet F_{X_{(n)}}(y) = P(X_{(n)} \leq y) = (F(y))^n \Rightarrow f_{X_{(n)}}(y) = \frac{\partial F_{X_{(n)}}}{\partial y} = n(F(y))^{n-1} f(y) = n(y - \theta + \frac{1}{2})^{n-1}$$

$$\bullet F_{X_{(1)}}(y) = 1 - (1 - F(y))^n \Rightarrow f_{X_{(1)}}(y) = n[1 - F(y)]^{n-1} f(y) = n(\theta - y + \frac{1}{2})^{n-1}$$

$$\rightarrow E[X_{(n)}] = \int_{\theta - \frac{1}{2}}^{\theta + \frac{1}{2}} n y (y - \theta + \frac{1}{2})^{n-1} dy = \frac{n}{n+1} + \theta - \frac{1}{2}$$

$$\rightarrow E[X_{(1)}] = \int_{\theta - \frac{1}{2}}^{\theta + \frac{1}{2}} n (\theta - y + \frac{1}{2})^{n-1} dy = \theta + \frac{1}{2} - \frac{n}{n+1}$$

(Dado que $X_{(1)}, \dots, X_{(n)}$ son independientes, luego no se puede hacer $f(X_{(1)}) \cdot f(X_{(n)})$)

$$\Rightarrow E[X_{(n)} - X_{(1)}] = \frac{n-1}{n+1} \neq h(\theta) = \theta \Rightarrow T \text{ no es centrado para } h(\theta) = \theta$$

5. Para una m.a.s de tamaño n de una población Binomial Negativa $(1, \theta)$, obtener el ECMV para $h(\theta) = P_0(X=0)$.

Se trata de una población Binomial Negativa $(1, \theta)$, luego

$$P(X_{1,1,0}) = \binom{x+r-1}{x} \theta^r (1-\theta)^x, \quad x=0, 1, 2, \dots \quad \theta > 0 \\ r=1$$

$$h(\theta) = P_0(X=0) = \theta$$

$$P_\theta(\vec{x}) = \theta^n (1-\theta)^{\sum_{i=1}^n x_i} \Rightarrow \ln(P_\theta(\vec{x})) = \ln \theta^n + n \ln \theta + \left(\sum_{i=1}^n x_i \right) \ln(1-\theta)$$

$$\Rightarrow \frac{\partial}{\partial \theta} (\ln(P_\theta(\vec{x}))) = \frac{n}{\theta} + \left(\sum_{i=1}^n x_i \right) \left(-\frac{1}{1-\theta} \right) = \frac{1}{1-\theta} \left[\underbrace{\sum_{i=1}^n x_i}_{T(\vec{x})} - \underbrace{\frac{n(1-\theta)}{\theta}}_{h(\theta)} \right]$$

$$\Rightarrow \text{ECMV para } h(\theta) = \frac{n(1-\theta)}{\theta}$$

• Construimos $w = \begin{cases} 1 & \text{si } x_1 = 0 \\ 0 & \text{en otro caso} \end{cases}$

$$\rightarrow P(w=1) = P(x_1=0) \rightarrow E[w] = 1 \cdot P(x_1=0) = \theta$$

$$P_\theta(\vec{x}) = \theta^n (1-\theta)^{\sum_{i=1}^n x_i} = \theta^n e^{\left(\sum_{i=1}^n x_i \right) \ln(1-\theta)}$$

$$\rightarrow \left. \begin{aligned} \eta(\theta) &= \theta^n \\ T(\vec{x}) &= \sum_{i=1}^n x_i \\ g(\theta) &= \ln(1-\theta) \end{aligned} \right\} \begin{array}{l} \text{FAMILIA EXPONENCIAL} \\ \text{UNIPARAMÉTRICA} \end{array}$$

$\Rightarrow T(\vec{x}) = \sum_{i=1}^n x_i$ es suficiente, y además, es completo, ya que

$$\begin{aligned} Q: \theta &\longrightarrow \mathbb{R} \\ \theta &\longrightarrow \ln(1-\theta) \\ \theta > 0 \end{aligned} \quad \text{contiene un intervalo}$$

$\Rightarrow T(\vec{x})$ es minimalmente suficiente

• $H(t) = E[w|T] = 1 \cdot P(w=1|T) = P(w=1, \sum_{i=1}^n x_i = t) = P(x_1=0, \sum_{i=1}^n x_i = t) =$

$$= P(x_1=0) \cdot P\left(\sum_{i=1}^n x_i = t\right) = \frac{\binom{t+n-1-1}{t} \theta^{n-1} (1-\theta)^t}{\binom{t+n-1}{t} \theta^n (1-\theta)^t} = \frac{n-1}{t+n-1}$$

$\uparrow$ La suma de x_i
 Binomiales negativas
 es $BN(n, \theta)$

¿Cómo lo saca?

$$\Rightarrow E[w|T] = \frac{n-1}{t+n-1}$$

$\Rightarrow$ Por Lehman-Scheffé: ECMV para $h(\theta) = P_0(X=0) \equiv \boxed{T(\vec{x}) = \frac{n-1}{t+n-1}}$

PROBLEMAS TEMA 4. PARTE 2

1. Para una m.a.s de tamaño 1 de una población $N(0, \sigma^2)$, se pide:
- Obtener un estimador centrado para σ^2 .
 - ¿Cuál es el EMV para σ ?

a) Buscamos T tal que $E[T(x)] = \sigma^2$

Probemos algunos:

$$E[X] = 0 \quad \times$$

$$E[S^2] = \sigma^2 \quad \checkmark$$

$$E[X] = 0 \quad \times$$

$$E[X^2] = V(X) + (E[X])^2 = \sigma^2 \quad \checkmark$$

Nos quedaremos con $\boxed{T = X^2}$, que es más fácil de trabajar que S^2 .

b) Se trata de una población normal $(0, \sigma^2)$, luego

$$f_0(x) = \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2\sigma^2} x^2} \quad -\infty < x < \infty$$

$$\sigma > 0$$

Hacemos $\ln$ en ambos lados:

$$\ln f_0(x) = -\ln \sqrt{2\pi} - \ln \sigma - \frac{1}{2\sigma^2} x^2$$

$$\frac{\partial}{\partial \sigma} (\ln f_0(x)) = -\frac{1}{\sigma} + \frac{x^2}{\sigma^3} = 0 \Rightarrow \frac{x^2}{\sigma^3} = \frac{1}{\sigma} \Rightarrow x^2 = \sigma^2$$


De modo que $\boxed{\hat{\sigma} = |x|}$

Veamos si es máximo absoluto:

$$\frac{\partial^2}{\partial \sigma^2} (\ln f_0(x)) = \frac{1}{\sigma^2} - \frac{3x^2}{\sigma^4} = \frac{1}{\sigma^2} - \frac{3\sigma^2}{\sigma^4} = -\frac{2}{\sigma^2} < 0 \Rightarrow \text{Máximo relativo}$$

$$\hat{\sigma} = |x|$$

¿Absoluto?



El punto crítico es el estimador

$$\hat{\sigma} = |x|$$

$$-\sigma^2 + x^2 < 0$$

$$x^2 < \sigma^2$$

$$-\infty < x < \infty$$

$$|x| > 0 \rightarrow \max |x|$$

$$|x| < 0 \rightarrow \max 0 \notin \text{dominio}$$

?

$\Rightarrow$ No existe el EMV porque el máximo puede estar en el caso en el que no pertenece al dominio

2. Para una m.a.s de tamaño n de una población $U(0, \theta)$, encontrar el/los estimadores de máxima verosimilitud.

Lo podríamos ^{hacer} como en el ejercicio 1, pero observamos que $x \in (0, \theta)$, por lo que basta estudiar el máximo de $f_{\theta}(\bar{x}) = \frac{1}{\theta^n}$

$$+ + + + +$$

$$0 \quad x_{(1)} \quad x_{(n)} \quad \theta$$

$$\theta \in [x_{(n)}, \infty) \Rightarrow \boxed{\text{El EMV es } x_{(n)}}$$

3. Para una m.a.s de tamaño n de una población $N(0, 1)$, sólo se registra si cada observación es menor o igual que cero o mayor. Si sabe que ha habido m valores menores o iguales que cero, con $m \leq n$, encontrar el EMV de θ .

Definimos $\begin{cases} 1 & \text{menor o igual que cero} \\ 0 & \text{mayor que cero} \end{cases}$ (Bernoulli)

es decir, $Y_i = \begin{cases} 1 & x_i \leq 0 \\ 0 & \text{otro caso} \end{cases}$

$$\sum_{i=1}^n Y_i = m \leq n \quad (\text{ha habido } m \text{ valores } \leq 0)$$

$$Pr(Y_i = 1) = Pr(X_i \leq 0) = F(x_i) \xrightarrow{N(0,1) \rightarrow \text{Tipificamos para una } N(0,1)} Pr(X_i - 0 \leq -0) = 1 - Pr(X_i - 0 \geq 0) = 1 - (1 - Pr(X_i - 0 \leq 0))$$

$$(1 - \phi(0)) = \phi(0) \quad \phi \rightarrow \text{función característica de la } N(0,1)$$

$$\Rightarrow Pr(Y_i = 1) = 1 - \phi(0)$$

$$\sum_{i=1}^n Y_i = m \leq n$$

$$f_{\theta}(\bar{x}) = \theta^{\sum_{i=1}^n Y_i} (1-\theta)^{n - \sum_{i=1}^n Y_i}$$

Hacemos $\ln$:

$$\sigma_n - \theta \sum x_i = \sum x_i - \theta \sum x_i \rightarrow \hat{\sigma} = \frac{\sum x_i}{n}$$

$$\ln f_{\theta}(\bar{x}) = \left(\sum_{i=1}^n Y_i \right) \ln \theta + \left(n - \sum_{i=1}^n Y_i \right) \ln(1-\theta)$$

$$\frac{\partial}{\partial \theta} \ln f_{\theta}(\bar{x}) = \frac{\sum_{i=1}^n Y_i}{\theta} - \frac{(n - \sum_{i=1}^n Y_i)}{1-\theta} = 0 \Rightarrow \boxed{\hat{\theta} = \bar{x}}$$

Con la segunda derivada < 0 comprobamos que es máximo relativo
 γ , después, hay que ver que no se produce en los extremos,
 hallamos máximo global $\Rightarrow \hat{\theta} = \bar{x}$ EMV para $1 - \phi(0)$

$$\bullet \phi(0) = 1 - \gamma \xrightarrow{\gamma} 1 - \phi(0) = g(0) = \gamma$$

$$\hat{\theta} = \phi^{-1}(1 - \gamma) \xrightarrow{\gamma} \phi(0) = -g(0) + 1 \Rightarrow \theta = \phi^{-1}(-g(0) + 1)$$

(Hacemos esto porque hemos hallado el EMV para $1 - \phi(0)$, pero lo queremos para θ)


¿Y ahora qué? ¿Solución?

4. Determinar los EMV, con m.a.s de tamaño n , para θ en los siguientes casos:

a) $f(x|\theta) = \frac{1}{\theta} I_{[1,2,\dots,\theta]}(x)$, θ entero positivo

b) $f(x|\theta) = e^{-x+\theta} I_{[0,\infty)}(x)$, $\theta \in \mathbb{R}$


a) $f_{\theta}(\vec{x}) = \frac{1}{\theta^n} \prod_{i=1}^n I_{[1,2,\dots,\theta]}(x_i)$
 $\downarrow$
 $I_{[1,\theta]}(x_1) \cdot \prod I_{[1,\theta]}(x_i)$



$\theta \in [x_{(n)}, \infty) \Rightarrow \boxed{x_{(n)} \text{ EMV}}$

• NOTA: Siempre buscamos $\ln \dots$
 y cuando nos den cosas raras
 observamos qué es lo que hace
 máxima la función
 $\rightarrow$ Si está acotada por el parámetro
 van a ser máx o mín $x_{(1)}, x_{(n)}$
 $\rightarrow$ Si no, si es cerrado $\odot$ si y si es
 abierto no va a existir

b) $f_{\theta}(\vec{x}) = e^{-\sum_{i=1}^n x_i + n\theta}$
 $\leftarrow$ Si fuera $I_{[0,\infty)}$



$\theta \in (-\infty, x_{(1)}] \Rightarrow \boxed{\text{El EMV es } x_{(1)}}$

$\rightarrow$ En nuestro caso: $I_{[0,\infty)}$

$f_{\theta}(\vec{x}) = e^{-\sum_{i=1}^n x_i + n\theta}$ $0 \leq x_i < \infty$

$\ln f_{\theta}(\vec{x}) = -\sum_{i=1}^n x_i + n\theta$
 $\downarrow$ Carlos tiene $\theta = 0$

$\frac{\partial}{\partial \theta} (\ln f_{\theta}(\vec{x})) = n = 0 \Rightarrow \text{¿Conclusión? ¿No hay?}$

• Otro caso: $I_{[0,8]}(x)$, $\theta \in [0,8]$

EMV $\rightarrow 8$

PROBLEMAS TEMA 4. PARTE 3

1. Para una m.a.s de tamaño n de una población Poisson(θ), supuesto que la distribución inicial a priori del parámetro θ viene dada por una distribución Gamma(a, p), con $a > 0, p > 0$. Se pide:

- Probar que la familia Gamma es conjugada respecto a la población Poisson.
- Calcular la media y la varianza de la distribución final.
- Calcular la pérdida final esperada para el estimador bayesiano.

a) m.a.s tamaño n Poisson(θ)

$$\pi(\theta) \sim \text{Gamma}(a, p)$$

$$\text{Tenemos que ver que } \pi(\theta|\vec{x}) \sim \text{Gamma}(a_1, p_1)$$

Se trata de una población Poisson(θ), luego $f_\theta(\vec{x}) = e^{-n\theta} \theta^{\sum x_i}$, $\theta > 0$

$$\pi(\theta) = \underbrace{\frac{a^p}{\Gamma(p)}}_{\text{Gamma}} e^{-a\theta} \theta^{p-1}, \quad a, p > 0$$

De modo que

$$\pi(\theta|\vec{x}) = \frac{f_\theta(\vec{x}) \cdot \pi(\theta)}{\int_0^\infty f_\theta(\vec{x}) \pi(\theta) d\theta} = \frac{\theta^{\sum x_i} e^{-n\theta}}{\frac{\Gamma(p)}{a^p}} \sim \text{Gamma}(a_1, p_1)$$

$$\int_0^\infty f_\theta(\vec{x}) \pi(\theta) d\theta = \int_0^\infty e^{-n\theta} \theta^{\sum x_i} e^{-a\theta} \theta^{p-1} d\theta = \int_0^\infty \theta^{\sum x_i + p - 1} e^{-(n+a)\theta} d\theta =$$

$$= \int_0^\infty \theta^{\sum x_i + p - 1} e^{-(n+a)\theta} d\theta = \frac{\Gamma(p_1)}{a_1^{p_1}}$$

$$a_1 = n + a$$

$$p_1 - 1 = \sum x_i + p - 1 \rightarrow p_1 = \sum x_i + p$$

$$\Rightarrow \boxed{\pi(\theta|\vec{x}) \sim \text{Gamma}(a_1, p_1)} \\ \begin{matrix} a_1 = n + a \\ p_1 = \sum x_i + p \end{matrix}$$

¿ $L(\theta, \hat{\theta}) = L(\theta, \hat{\theta})^2$, $\hat{\theta} = E[\pi(\theta|\tilde{x})]$? Para $\theta = 1$?

$$b) \frac{E[\pi(\theta|\tilde{x})]}{E[\theta]} = \int_0^{\infty} \theta \frac{a_1^{p_1}}{\Gamma(p_1)} \theta^{p_1-1} e^{-a_1\theta} d\theta = \frac{a_1^{p_1}}{\Gamma(p_1)} \int_0^{\infty} \theta^{p_1} e^{-a_1\theta} d\theta =$$

$\theta \sim \pi(\theta|\tilde{x})$

$$= \frac{a_1^{p_1}}{\Gamma(p_1)} \int_0^{\infty} \theta^{p_1} e^{-a_1\theta} d\theta = \frac{a_1^{p_1}}{\Gamma(p_1)} \frac{\Gamma(p_1+1)}{a_1^{p_1+1}} = \frac{p_1 \Gamma(p_1)}{a_1 \Gamma(p_1)} = \frac{p_1}{a_1}$$

$$p_1-1 = p_1 \rightarrow p_1 = p_1+1$$

$$\frac{\Gamma(p_1+1)}{a_1^{p_1+1}}$$

¿Fracción o adición?

$$\Rightarrow \boxed{\frac{E[\pi(\theta|\tilde{x})]}{E[\theta]} = \frac{p_1}{a_1}}$$

$$\bullet V(\theta) = E[\theta^2] - (E[\theta])^2$$

$$E[\theta^2] = \int_0^{\infty} \theta^2 \frac{a_1^{p_1}}{\Gamma(p_1)} \theta^{p_1-1} e^{-a_1\theta} d\theta = \frac{a_1^{p_1}}{\Gamma(p_1)} \int_0^{\infty} \theta^{p_1+1} e^{-a_1\theta} d\theta = \frac{a_1^{p_1}}{\Gamma(p_1)} \frac{\Gamma(p_1+2)}{a_1^{p_1+2}} =$$

$$p_1-1 = p_1+1 \rightarrow p_1 = p_1+2$$

$$= \frac{(p_1+1) \Gamma(p_1+1)}{\Gamma(p_1) a_1^2} = \frac{(p_1+1) p_1 \Gamma(p_1)}{\Gamma(p_1) a_1^2} = \frac{p_1(p_1+1)}{a_1^2}$$

$$\Rightarrow V(\theta) = \frac{p_1(p_1+1)}{a_1^2} - \frac{p_1^2}{a_1^2} = \frac{p_1^2 + p_1 - p_1^2}{a_1^2} = \frac{p_1}{a_1^2}$$

$$\Rightarrow \boxed{V(\theta) = \frac{p_1}{a_1^2}}$$

c) El estimador bayesiano será la esperanza, es decir,

$$\boxed{E.B = \frac{p_1}{a_1}}$$

Y la pérdida final esperada será la varianza, es decir,

$$\boxed{P.FE = \frac{p_1}{a_1^2}}$$

2. Se tiene la sospecha de que una moneda está sesgada, en el sentido de que su probabilidad de cara es menor que 0.5. Si esta información se modela mediante una distribución Beta (10,8) como distribución inicial, ¿cuál es el estimador bayesiano cuando después de tirar la moneda 50 veces se obtienen 20 caras? Utilizar como función pérdida el valor absoluto.

Se trata de una población $X \sim \text{Bernoulli}$, luego $f_0(\vec{x}) = \theta^{\sum x_i} (1-\theta)^{n-\sum x_i}$
 $X_1, \dots, X_n, n=50$ (se tira 50 veces la moneda)

$$\pi(\theta) = \text{Beta}_{p_0, q_0}(10, 8)$$

$$\sum_{i=1}^n x_i = 20 \text{ (Se obtienen 20 caras)}$$

[$L = (\theta - \hat{\theta})$ Mediana?
 ¿Para qué?]

$$\pi(\theta) = \frac{1}{\beta(10, 8)} \theta^{10-1} (1-\theta)^{8-1} \mathbb{I}_{(0,1)}(\theta)$$

$$\begin{aligned} \pi(\theta|\vec{x}) &= \frac{f_0(\vec{x})\pi(\theta)}{\int_0^1 f_0(\vec{x})\pi(\theta)d\theta} = \frac{\theta^{\sum x_i + p_0 - 1} (1-\theta)^{n - \sum x_i + q_0 - 1}}{\int_0^1 \theta^{\sum x_i + p_0 - 1} (1-\theta)^{n - \sum x_i + q_0 - 1} d\theta} = \frac{\theta^{p_1 - 1} (1-\theta)^{q_1 - 1}}{\beta(p_1, q_1)} = \\ &= \frac{\theta^{20} (1-\theta)^{30}}{\beta(30, 38)} \sim \text{Beta}(30, 38) \\ &\quad \uparrow \quad \quad \quad \uparrow \\ &\quad p_1 = 20 + 10 \quad \quad \quad q_1 = 50 - 20 + 8 \end{aligned}$$

Habría que hallar la esperanza ¿no?

3. La proporción θ de votantes a un determinado partido político en unas elecciones es desconocida y su distribución inicial es Beta(4,10).

- Se toma una m.a.s de 1000 votantes y se encuentra que 125 van a votar al partido político. Con pérdida cuadrática, ¿cuál es el estimador bayesiano para θ ?
- Si se cambia el sistema de muestreo y se necesitan 1000 personas hasta conseguir que 125 voten al partido, ¿cuál es el estimador bayesiano para θ con pérdida cuadrática?

a) $\theta \sim \text{Beta}(4, 10)$ $\theta \sim \text{proporción votantes A}$
 $n = 1000$
 $\sum x_i = 125$

$$\pi(\theta|\vec{x}) = \text{Beta}(p_0 + \sum x_i, n - \sum x_i + q_0) = \text{Beta}(129, 885)$$

$$\begin{aligned} \hat{\theta} &= E[\pi(\theta|\vec{x})] = \int_0^1 \theta \frac{1}{\beta(p_1, q_1)} \theta^{p_1-1} (1-\theta)^{q_1-1} d\theta = \frac{1}{\beta(p_1, q_1)} \int_0^1 \theta^p (1-\theta)^{q-1} d\theta = \\ &= \frac{\beta(p+1, q)}{\beta(p, q)} = \frac{\frac{p! (q-1)!}{(p+q)!}}{\frac{p! (q-1)!}{(p+q)!}} = \frac{p! (q-1)!}{(p+q)!} \cdot \frac{(p+q)!}{p! (q-1)!} = \frac{p}{p+q} \\ &\Rightarrow \boxed{\hat{\theta} = \frac{p}{p+q}} \end{aligned}$$

3) $K = 125$ éxitos

$K = 125$
 $X = 1000$

$$f_{\theta}(\vec{x}) = \text{BN}(x|K, \theta) = \binom{x-1}{x-K} \theta^K (1-\theta)^{x-K} = \binom{999}{875} \theta^{125} (1-\theta)^{875}$$

$$f_{\theta}(\vec{x}) \pi(\theta) = \binom{999}{875} \theta^{125} (1-\theta)^{875} \sim \text{Beta}(125, 885)$$

apartado a)

→ Hallamos $\pi(\theta|\vec{x}) = \frac{f_{\theta}(\vec{x}) \pi(\theta)}{\int_0^1 f_{\theta}(\vec{x}) \pi(\theta) d\theta}$ y hallamos su esperanza

4. A una persona se le pasa un test de inteligencia, cuyo resultado X se supone que sigue una distribución Normal($\theta, \sigma^2 = 10$), donde θ es su nivel de inteligencia real. Supongamos que en el colectivo al que pertenece la persona, la inteligencia θ se distribuye según Normal($100, \sigma^2 = 15$). ¿Cuál sería el estimador bayesiano de θ si se supone pérdida cuadrática? ¿Cuánto valdrá éste si la persona tiene como resultado del test el valor 110? ¿Cuál es la pérdida final esperada correspondiente?

$$X \sim N(\theta, 10)$$

θ nivel de inteligencia

$$\theta \sim N(100, 15) \sim \pi(\theta)$$

$$n = 1 \rightarrow \frac{\sum X_i}{n} = 110 = \bar{X}$$

$$\pi(\theta|\vec{x}) \sim N(\mu_1, \sigma_1^2)$$

$$\mu_1 = \frac{\frac{\mu_0}{\sigma_0^2} + \bar{X} \frac{n}{\sigma^2}}{\frac{1}{\sigma_0^2} + \frac{n}{\sigma^2}} = \frac{\frac{100}{15^2} + 110 \cdot \frac{1}{10^2}}{\frac{1}{15^2} + \frac{1}{10^2}} = 106'923$$

$\bar{X} = 110$
 $\sigma_0^2 = 15^2$
 $\sigma^2 = 10^2$

$$E[\pi(\theta|\vec{x})] = \mu_1 \text{ estimador bayesiano}$$

$$\sigma_1^2 = \frac{1}{\frac{1}{\sigma_0^2} + \frac{n}{\sigma^2}} = \frac{1}{\frac{1}{15^2} + \frac{1}{10^2}} = 69'23$$

$$\sigma_1^2 = V[\pi(\theta|\vec{x})] \text{ pérdida final esperada}$$

(• Continuação de 3.5)

$$\pi(\theta|x) = \frac{\theta^{129} (1-\theta)^{884}}{\int_0^1 \theta^{\sum x_i + p_0 - 1} (1-\theta)^{n - \sum x_i + q_0 - 1} d\theta}$$

$$\int_0^1 \theta^{\sum x_i + p_0 - 1} (1-\theta)^{n - \sum x_i + q_0 - 1} d\theta \sim \beta(129, 885)$$

$$p_1 = \sum x_i + p_0 = 129$$

$$q_1 = n - \sum x_i + q_0 = 885$$

$$\begin{aligned} \frac{E[\pi(\theta|x)]}{E[\theta]} &= \int_0^1 \theta \frac{\theta^{129} (1-\theta)^{884}}{\beta(129, 885)} d\theta = \int_0^1 \frac{\theta^{130} (1-\theta)^{884}}{\beta(129, 885)} d\theta = \frac{1}{\beta(129, 885)} \int_0^1 \theta^{130} (1-\theta)^{884} d\theta \\ &= \frac{\beta(130, 885)}{\beta(129, 885)} = \frac{\frac{\Gamma(130) \Gamma(885)}{\Gamma(1015)}}{\frac{\Gamma(129) \Gamma(885)}{\Gamma(1014)}} = \frac{\Gamma(130) \Gamma(1014)}{\Gamma(129) \Gamma(1015)} = \\ &= \frac{129 \Gamma(129) \Gamma(1014)}{\Gamma(129) \cdot 1014 \Gamma(1014)} = \frac{129}{1014} = \frac{43}{338} \approx 0.127 \leftarrow \text{Estimador Bayesiano} \end{aligned}$$

$$\begin{aligned} E[\theta^2] &= \int_0^1 \theta^2 \frac{\theta^{129} (1-\theta)^{884}}{\beta(129, 885)} d\theta = \frac{\beta(131, 885)}{\beta(129, 885)} = \frac{\frac{\Gamma(131) \Gamma(885)}{\Gamma(1016)}}{\frac{\Gamma(129) \Gamma(885)}{\Gamma(1014)}} = \frac{\Gamma(131) \Gamma(1014)}{\Gamma(129) \Gamma(1016)} \\ &= \frac{130 \cdot 129 \Gamma(129) \Gamma(1014)}{\Gamma(129) \cdot 1014 \Gamma(1016)} = \frac{215}{13} \approx 16.538 \end{aligned}$$

$$V(\theta) = \frac{215}{13} - \left(\frac{43}{338} \right)^2 \approx 16.522 \leftarrow \text{P.F.E}$$

⑧ H4.1

17-05-2017

Sea una m.a.s. de tamaño n , con función de densidad

$$(a) f_{\theta}(x) = \frac{1}{\theta} e^{-x/\theta} I_{(0,\infty)}(x), \quad \theta > 0$$

Obtener la cota de Fisher y un estimador eficiente

$$f_{\theta}(\vec{x}) = \frac{1}{\theta^n} e^{-\frac{1}{\theta} \sum_{i=1}^n x_i} \prod_{i=1}^n I_{(0,\infty)}(x_i)$$

$$\ln f_{\theta}(\vec{x}) = -n \ln \theta - \frac{1}{\theta} \sum_{i=1}^n x_i$$

$$\frac{\partial}{\partial \theta} \ln f_{\theta}(\vec{x}) = -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i = \underbrace{\frac{1}{\theta^2}}_{k(\theta)} \left[\underbrace{\sum_{i=1}^n x_i}_{T(x_1, \dots, x_n)} - \underbrace{n\theta}_{h(\theta)} \right] \quad [T(x_1, \dots, x_n) - h(\theta)]$$

$$\Rightarrow k(\theta) = \frac{1}{\theta^2}$$

$$T(x_1, \dots, x_n) = \sum_{i=1}^n x_i$$

$$h(\theta) = n\theta$$

$$k(\theta) = \frac{I_n(\theta)}{h'(\theta)} = \frac{1}{\theta^2} \Rightarrow I_n(\theta) = k(\theta) \cdot h'(\theta) = \frac{1}{\theta^2} \cdot n = \frac{n}{\theta^2}$$

$$\Rightarrow \boxed{\text{COTA} = \frac{h'(\theta)}{k(\theta)} = n\theta^2} \rightarrow \text{Estimador eficiente} = \sum_{i=1}^n x_i$$

(alcanza la cota para $h(\theta) = n\theta$)

$$\text{COTA} = \frac{(h'(\theta))^2}{I_n(\theta)} = \frac{n^2}{\frac{n}{\theta^2}} = n\theta^2$$

$$(b) p_{\theta}(x) = \theta(1-\theta)^x, \quad x = 0, 1, 2, \dots \quad 0 < \theta < 1$$

$$\ln p_{\theta}(\vec{x}) = n \ln \theta + \sum_{i=1}^n x_i (\ln(1-\theta))$$

$$\frac{\partial}{\partial \theta} \ln p_{\theta}(\vec{x}) = \frac{n}{\theta} - \left(\sum_{i=1}^n x_i \right) \cdot \frac{1}{1-\theta} = -\frac{n}{1-\theta} \left[\frac{\sum_{i=1}^n x_i}{n} - \frac{(1-\theta)}{n} \right]$$

$$\text{COTA} = \frac{h'(\theta)}{k(\theta)} = \frac{-\frac{1}{\theta^2}}{-\frac{n}{1-\theta}} = \frac{1-\theta}{n\theta^2}$$

$$\text{Estimador eficiente} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}$$

⑥ H4.1

Para una m.a.s. de tamaño n de una población Bernoulli (θ) dado un número entero conocido con $0 < s < n$, obtener el ECMV para

(a) $h(\theta) = \theta^s$

$$T(X) = \sum_{i=1}^n x_i \quad \text{sufc. completo}$$

$$H(T) \text{ ECMV}$$

$$E[H(T)] = h(\bar{\theta})$$

$$P(X=x) = \theta$$

$$W \in U_n$$

$$H(T) = E[W/T]$$

$$W \in U_n, T \text{ suf. comp.}$$

$$E[W] = h(\theta) = \theta^s$$

$$W = \begin{cases} 1 & x_1 x_2 \dots x_s = 1 \\ 0 & \text{otro caso} \end{cases}$$

$$E[W] = 1 \cdot \Pr(W=1) = \Pr(x_1 \dots x_s = 1) = \Pr(x_i = 1)^s$$

$$E[W/T] = 1 \cdot \Pr(W=1) = \frac{P(x_1 \dots x_s = 1, \sum_{i=1}^n x_i = t)}{P(\sum_{i=1}^n x_i = t)} \quad \text{Binomial}(n, \theta)$$

$$\Pr(\sum_{i=1}^n x_i = t)$$