

## EJERCICIOS TEMA 2

- 1º a) Demuestre que la media muestral es siempre un estimador inservado y consistente (en media cuadrática) de la media poblacional (supuesto que la varianza poblacional es finita)
- b) Demuestre igualmente, que la cuasivarianza muestral es un estimador inservado de la varianza poblacional y que, sin embargo, la varianza muestral solo lo es asintóticamente
- Solución
- a) Sea  $X$  una r.a. distribuida de modo que su media poblacional es  $E[X] = \mu$  y su varianza poblacional es  $\text{Var}[X] = \sigma^2$ . Seleccionaremos una m.a.s.  $x_1, x_2, \dots, x_n$  y consideraremos el estadístico:

$$T(x_1, x_2, \dots, x_n) = \frac{\sum_{i=1}^n x_i}{n}$$

Entonces:

$$E[T] = E\left[\frac{\sum_{i=1}^n x_i}{n}\right] = \frac{1}{n} E\left[\sum_{i=1}^n x_i\right] = \frac{1}{n} \sum_{i=1}^n E[x_i] =$$

$$= \frac{1}{n} \sum_{i=1}^n \mu = \frac{1}{n} \cdot n \mu = \mu \Rightarrow T \text{ es un estimador inservado para el parámetro } \mu \text{ (media poblacional)}$$

Veamos que  $T$  es consistente en media cuadrática.

$$E[CM(T)] = \text{Var}\left[\frac{\sum_{i=1}^n x_i}{n}\right] = \frac{1}{n^2} \cdot \text{Var}\left[\sum_{i=1}^n x_i\right]$$

Como los  $x_i$   $i = 1 \dots n$  son independientes entonces

$$\text{Var}\left[\sum_{i=1}^n x_i\right] = \sum_{i=1}^n \text{Var}[x_i] = \sum_{i=1}^n \sigma^2 = n \sigma^2$$

luego:

$$E[CM(T)] = \frac{1}{n^2} \cdot n \sigma^2 = \frac{\sigma^2}{n} \cdot \text{Por tanto:}$$

$$\lim_{n \rightarrow \infty} E[CM(T)] = \lim_{n \rightarrow \infty} \frac{\sigma^2}{n} = 0 \Rightarrow T \text{ es consistente en media cuadrática}$$

Tenemos que si  $s^2$  es la varianza muestral y  $s_c^2$  es la cuasivarianza muestral entonces:

$s_c^2 = \frac{n}{n-1} s^2$ . Además la relación entre la varianza muestral y la varianza poblacional es:

$$E[s^2] = \frac{n-1}{n} \cdot \sigma^2 \Rightarrow s^2 \text{ no es invergado para } \sigma^2$$

luego  $E[s_c^2] = \frac{n}{n-1} \cdot \frac{n-1}{n} \cdot \sigma^2 \Rightarrow E[s_c^2] = \sigma^2 \Rightarrow s_c^2$  es un estimador invergado del parámetro  $\sigma^2$

$s^2$  es un estimador asintóticamente invergado para  $\sigma^2$  ya que:

$$\lim_{n \rightarrow \infty} E[s^2] = \lim_{n \rightarrow \infty} \frac{n-1}{n} \sigma^2 = \sigma^2.$$

2 Consideremos una m.a.s. extraída de una población  $U(0, \theta)$  donde  $\theta \in \mathbb{R}^+$ . Sean los estadísticos  $Y_n = 2\bar{x}_n$  y  $M_n = \max \{x_1, x_2, \dots, x_n\}$ . Demuestre que  $Y_n$  es un estimador invergado de  $\theta$  y que  $M_n$  lo es asintóticamente.

Se tiene que

$$Y_n = 2\bar{x}_n = \frac{2 \sum_{i=1}^n x_i}{n} \Rightarrow E[Y_n] = \frac{2}{n} \cdot E[\sum_{i=1}^n x_i]$$

$$E[Y_n] = \frac{2}{n} \cdot \sum_{i=1}^n E[x_i] \quad (\text{como } x_i \sim U(0, \theta) \Rightarrow E[x_i] = \frac{0+\theta}{2} = \frac{\theta}{2})$$

Por tanto:

$$E[Y_n] = \frac{2}{n} \cdot \sum_{i=1}^n \frac{\theta}{2} = \frac{2}{n} \cdot \frac{n\theta}{2} = \theta$$

Hemos demostrado que  $Y_n$  es invergado para  $\theta$ , pero hay una sutileza que se nos escapa, ¿es  $Y_n$  estimador de  $\theta$ ? Veamos,  $Y_n$  es un estadístico ya que no contiene en su definición parámetros desconocidos. Veamos el campo de variación de  $Y_n$ . La función de densidad de  $U(0, \theta)$  es

$$f_\theta(x) = \begin{cases} \frac{1}{\theta} & \text{si } 0 < \theta < x \\ 0 & \text{en el resto} \end{cases}$$

El campo de variación de  $x_i$  es  $(0, \theta)$   $\forall i=1, \dots, n \Rightarrow$   
 $\Rightarrow 0 < x_i < \theta \Rightarrow 0 < \sum^n x_i < \sum^n n\theta \Rightarrow 0 < \sum^n x_i < n\theta \Rightarrow$   
 $\Rightarrow 0 < \frac{\sum x_i}{n} < \theta \Rightarrow 0 < Y_n < \theta$

Por tanto  $Y_n$  es un estimador de  $\theta$

Tenemos que hallar  $E[M_n]$ . Para ello nos hace falta la función de densidad de  $M_n$ , que obtendremos derivando la función de distribución. Esta función es:

$$F_{M_n}(t) = P[M_n < t] = P[\max\{x_1, x_2, \dots, x_n\} < t] = \\ = P[x_1 < t, x_2 < t, \dots, x_n < t] = \prod_{i=1}^n P[x_i < t]$$

Como  $P[x_i < t] = \begin{cases} 0 & \text{si } t < 0 \\ \int_0^t \frac{1}{\theta} dt & \text{si } 0 < t < \theta \\ 1 & \text{si } t > \theta \end{cases} = \begin{cases} \frac{t}{\theta} & \text{si } 0 < t < \theta \\ 0 & \text{en el resto} \end{cases}$

Tenemos que si  $0 < t < \theta$

$$F_{M_n}(t) = \prod_{i=1}^n \frac{t}{\theta} = \left(\frac{t}{\theta}\right)^n. \text{ Derivando obtenemos:}$$

$$f_{M_n}(t) = f_{M_n}(t) = n \cdot \left(\frac{t}{\theta}\right)^{n-1} \cdot \frac{1}{\theta} \quad \text{si } 0 < t < \theta$$

Entonces:

$$E[M_n] = \int_0^\theta t \cdot f_{M_n}(t) dt = \int_0^\theta n \cdot \frac{t^n}{\theta^n} dt = \frac{n}{\theta^n} \cdot \left[ \frac{t^{n+1}}{n+1} \right]_0^\theta$$

es decir que:

$$E[M_n] = \frac{n}{\theta^n} \cdot \frac{\theta^{n+1}}{n+1} = \frac{n}{n+1} \cdot \theta \Rightarrow M_n \text{ no es estimador inservido para } \theta.$$

$$\lim_{n \rightarrow \infty} E[M_n] = \lim_{n \rightarrow \infty} \frac{n}{n+1} \cdot \theta = \theta \Rightarrow M_n \text{ es estimador asintóticamente inservido para } \theta.$$

3º Dada una muestra aleatoria simple de tamaño 2, demuestre que el estimador  $T = x_1 + x_2$  es suficiente, tanto si la población sigue una distribución de Bernoulli como si sigue una distribución de Poisson. Utilice la definición de suficiencia y el criterio de factorización.

Solución: criterio de factorización

Si  $x \sim b(p)$  la función de probabilidad de  $x$  es:

$$P[X=x] = p^x \cdot (1-p)^{1-x} = (1-p) \cdot \left(\frac{p}{1-p}\right)^x =$$

$P[X=x] = (1-p) \cdot e^{x \cdot \ln \frac{p}{1-p}}$ , lo que nos indica que la distribución de Bernouilli pertenece a la familia exponencial ya que es de la forma

$P[X=x] = a(\theta) \cdot b(x) \cdot e^{c(\theta) \cdot d(x)}$  y en este caso si la muestra es de tamaño  $n$  el estimador suficiente para  $\theta$  es

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n d(x_i)$$

$$a(p) = 1-p \quad b(x) = 1 \quad c(p) = \ln \frac{p}{1-p} \quad d(x) = x$$

Como tomamos muestras de tamaño 2, el estadístico  $T(x_1, x_2) = x_1 + x_2$  es suficiente para  $p$

Si  $x \sim P(\lambda)$  la función de probabilidad de  $x$  es:

$$P[X=x] = \frac{\lambda^x \cdot e^{-\lambda}}{x!} = e^{-\lambda} \cdot \frac{1}{x!} \cdot \lambda^x =$$

$$P[X=x] = e^{-\lambda} \cdot \frac{1}{x!} \cdot e^{x \ln \lambda}, \text{ la distribución de}$$

Poisson tambien pertenece a la familia exponencial:

$$a(\lambda) = e^{-\lambda} \quad b(x) = \frac{1}{x!} \quad c(\lambda) = \ln \lambda \quad d(x) = x$$

Como tomamos muestras de tamaño 2, entonces  $T(x_1, x_2) = x_1 + x_2$  es un estadistico suficiente para  $\lambda$ .

Con la definición:

Si  $X \sim b(p)$  y tomamos una m.e.s. de tamaño 2,  $x_1, x_2$ , entonces el estadistico  $T = x_1 + x_2 \sim B(2, p)$

Tenemos que probar que  $P[x_1 = x_1, x_2 = x_2] / T(x_1, x_2) = x_1 + x_2 = t$  no depende de  $p$  cuando  $(x_1, x_2) \in N_t = \{(x_1, x_2) / T(x_1, x_2) = x_1 + x_2 = t\}$ , o sea:

$$\begin{aligned} P[x_1 = x_1, x_2 = x_2 / T = t] &= \frac{P[x_1 = x_1] \cdot P[x_2 = x_2]}{P(T = t)} \\ &= \frac{p^{x_1} \cdot (1-p)^{1-x_1} \cdot p^{x_2} \cdot (1-p)^{1-x_2}}{\binom{2}{t} \cdot p^t \cdot (1-p)^{2-t}} = \frac{p^{x_1+x_2} \cdot (1-p)^{2-(x_1+x_2)}}{\binom{2}{t} \cdot p^t \cdot (1-p)^{2-t}} \end{aligned}$$

Como  $x_1 + x_2 = t$

$$P[x_1 = x_1, x_2 = x_2 / T = t] = \frac{p^t \cdot (1-p)^{2-t}}{\binom{2}{t} \cdot p^t \cdot (1-p)^{2-t}} = \frac{1}{\binom{2}{t}}$$

$\Rightarrow T(x_1, x_2) = x_1 + x_2$  es suficiente ya que

$P[x_1 = x_1, x_2 = x_2 / T = t]$  no depende de  $p$ .

Con la definición:

Si  $X \sim P(\lambda)$  y tomamos una m.e.s. de tamaño 2,  $x_1, x_2$ , entonces el estadistico  $T(x_1, x_2) = x_1 + x_2 \sim P(2\lambda)$ .

$$P[x_1 = x_1, x_2 = x_2 / T = t] = \frac{P[x_1 = x_1] \cdot P[x_2 = x_2]}{P[T = t]}$$

Entonces:

$$P[X_1 = x_1, X_2 = x_2] = \frac{\frac{e^{-\lambda} \cdot \lambda^{x_1}}{x_1!} \cdot \frac{e^{-\lambda} \cdot \lambda^{x_2}}{x_2!}}{t!} =$$

$$= \frac{\cancel{e^{-2\lambda}} \cdot \lambda^{x_1 + x_2}}{x_1! x_2!} =$$

$$= \frac{\cancel{e^{-2\lambda} \cdot 2^t \cdot \lambda^t}}{t!} = \frac{2^t \cdot \cancel{\lambda^t}}{2^t \cdot x_1! x_2!} =$$

luego  $P[X_1 = x_1, X_2 = x_2 / T = t]$  no depende de  $\lambda$   
por lo que  $T(x_1, x_2) = x_1 + x_2$  es suficiente para  $\lambda$ .

4º Sean dos poblaciones una distribuida según una  $\text{G}(a, p)$  y la otra según una  $\beta(a, p)$ . Para cada una, calcule un estadístico suficiente bajo las siguientes hipótesis:

- $a$  es conocido y  $p$  desconocido
- $a$  desconocido y  $p$  conocido
- $a$  y  $p$  desconocidos.

FUNCION  $G(a, p)$

- $a$  conocido y  $p$  desconocido  
la función de densidad de una  $\text{G}(a, p)$  es:

$$f_p(x) = \frac{a^p}{\Gamma(p)} \cdot e^{-ax} \cdot x^{p-1} \quad \text{y la podemos expresar}$$

de esta forma también:

$$f_p(x) = \frac{a^p}{\Gamma(p)} \cdot e^{-ax} \cdot e^{(p-1)\ln x} \quad \text{si } a \text{ es conocido esta}$$

pertenece a la familia exponencial ya que se

puede expresar en la forma:

$$f_p(x) = \frac{a^p}{\Gamma(p)} \cdot e^{-ax} \cdot e^{(p-1)\ln x} = a(p) \cdot b(x) \cdot e^{c(p) \cdot d(x)}$$

donde:

$$a(p) = \frac{a^p}{\Gamma(p)} \quad b(x) = e^{-ax} \quad c(p) = p-1 \quad d(x) = \ln x$$

Si tomamos una muestra de tamaño  $n$ , el estadístico

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n \ln(x_i)$$

es suficiente para  $p$ , supuesto que  $a$  es conocido.

b)  $a$  desconocido y  $p$  conocido

Expresamos la función de densidad como:

$$f_a(x) = \frac{a^p}{\Gamma(p)} \cdot e^{(p-1)\ln x} \cdot e^{-ax}$$

que es de la

familia exponencial ya que se puede expresar como

$$f_a(x) = a(a) \cdot b(x) \cdot e^{c(a) \cdot d(x)}$$

$$a(a) = \frac{a^p}{\Gamma(p)} \quad b(x) = e^{(p-1)\ln x} = x^{p-1} \quad c(a) = -a \quad d(x) = x$$

Si tomamos una m.a.s.  $x_1, x_2, \dots, x_n$ , entonces el estadístico

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n x_i$$

es suficiente para  $a$  si  $p$  es conocido.

c) Si  $a$  y  $p$  son desconocidos

Observación sobre la familia exponencial

Si la v.a.  $x$  es  $n$ -dimensional y la función de probabilidad o densidad es de la forma:

$$f_\theta(x) = a(\theta) \cdot b(x) \cdot e^{\sum_i c_i(\theta) \cdot d_i(x)}$$

entonces el estadístico

$$T(x) = \left( \sum_{i=1}^n d_1(x_i), \sum_{i=1}^n d_2(x_i), \dots, \sum_{i=1}^n d_k(x_i) \right) \text{ es}$$

suficiente para  $\theta = (\theta_1, \theta_2, \dots, \theta_n)$

Suponiendo que  $a$  y  $p$  son desconocidos, la función de plenitud es:

$$f(a, p)(x) = \frac{a^p}{\Gamma(p)} \cdot e^{-ax} \cdot e^{(p-1)\ln x} = \frac{a^p}{\Gamma(p)} \cdot e^{-ax+(p-1)\ln x}$$

$$a(\theta) = \frac{a^p}{\Gamma(p)} \quad b(x) = 1 \quad g(\theta) = -a \quad c_2(\theta) = p-1$$

$$d_1(x) = x \quad d_2(x) = \ln x$$

Entonces  $T(x) = \left( \sum_{i=1}^n x_i, \sum_{i=1}^n \ln(x_i) \right)$  es estadísticamente suficiente para  $(a, p) = \theta$ , donde  $x_1, x_2, \dots, x_n$  es una m.a.s.

### FUNCION $\beta(a, p)$

$a$  conocido y  $p$  desconocido

la función de densidad de  $x$  es:

$$f_p(x) = \frac{1}{\beta(a, p)} \cdot x^{a-1} \cdot (1-x)^{p-1} = \frac{1}{\beta(a, p)} x^{a-1} e^{-(p-1)\ln(1-x)}$$

$$= a(p) \cdot b(x) \cdot e^{c(p) \cdot d(x)}$$

$$a(p) = \frac{1}{\beta(a, p)} \quad b(x) = x^{a-1} \quad c(p) = p-1 \quad d(x) = \ln(1-x)$$

lo que nos dice que la distribución beta pertenece a la familia exponencial y que el estadístico  $T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n \ln(1-x_i)$  es suficiente para  $p$  siendo  $a$  constante y  $0 < x_i < 1$ .

p conocido y a desconocido

la función de densidad se puede expresar como  
 $f(x) = \frac{1}{\beta(a,p)} \cdot x^{a-1} \cdot (1-x)^{p-1} = \frac{1}{\beta(a,p)} \cdot (1-x)^{p-1} \cdot e^{(a-1)\ln x}$

es de nuevo de la familia exponencial. El estadístico

$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n \ln x_i$  es suficiente para a  
siendo p conocido y  $0 < x_i < 1$ .

p y a desconocidos

Consideramos la variable bidimensional y  $\theta = (a, p)$   
entonces la función de densidad es:

$$f_\theta(x) = a(\theta) \cdot b(x) \cdot e^{c_1(\theta) \cdot d_1(x) + c_2(\theta) \cdot d_2(x)}$$

$$= \frac{1}{\beta(a,p)} \cdot e^{(a-1)\ln x + (p-1) \cdot \ln(1-x)}$$

$$a(\theta) = \frac{1}{\beta(a,p)} \quad b(x) = 1 \quad c_1(\theta) = a-1 \quad d_1(x) = \ln x$$

$$c_2(\theta) = p-1 \quad d_2(x) = \ln(1-x)$$

Entonces si  $x_1, x_2, \dots, x_n$  es m.a.s. el estadístico

$$T(x_1, x_2, \dots, x_n) = \left( \sum_{i=1}^n \ln x_i, \sum_{i=1}^n \ln(1-x_i) \right) \quad 0 < x_i < 1$$

es suficiente para  $\theta = (a, p)$

5º Suponga una población  $N(\mu, \sigma^2)$ . Compruebe que si  $\sigma$  es conocida, entonces  $\bar{x}$  es suficiente para  $\mu$  y que  $\sum_{i=1}^n (x_i - \mu)^2$  lo es para  $\sigma^2$  si  $\mu$  es conocido. Halle un

estadístico suficiente para los dos parámetros si ambos son desconocidos.

la función de densidad de la normal es

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

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

- Si  $\sigma$  es conocida, la función de densidad la podemos expresar como:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2\sigma^2}x^2} \cdot e^{\frac{\mu}{\sigma^2}x} \cdot e^{-\frac{\mu^2}{2\sigma^2}}, \text{ es decir}$$

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{\mu^2}{2\sigma^2}} \cdot e^{-\frac{1}{2\sigma^2}x^2} \cdot e^{\frac{\mu}{\sigma^2}x} \text{ que es de la familia exponencial ya que la función de densidad tiene la forma:}$$

$$f(x) = a(\mu) \cdot b(x) \cdot e^{c(\mu) \cdot d(x)}$$

$$a(\mu) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{\mu^2}{2\sigma^2}} \quad b(x) = e^{-\frac{1}{2\sigma^2}x^2} \quad c(\mu) = \frac{\mu}{\sigma^2} \quad d(x) = x$$

de esta forma para cualquier m.a.s.  $x_1, x_2, \dots, x_n$

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n d(x_i) = \sum_{i=1}^n x_i \text{ es un estadístico suficiente para } \mu. \text{ Como la aplicación } m(x) = \frac{x}{n} = \frac{1}{n}x \text{ es inyectiva, también es suficiente para } \mu \text{ el estadístico } m(T(x_1, x_2, \dots, x_n)) = \frac{\sum x_i}{n} = \bar{x}.$$

- Si  $\mu$  es conocido, la función de densidad la podemos escribir como

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

y si  $\mu$  es conocido pertenece a la familia exponencial ya que la podemos

expresar como:

$$f(x) = a(\sigma) \cdot b(x) \cdot e^{c(\sigma) \cdot d(x)} \quad \text{siendo}$$

$$a(\sigma) = \frac{1}{\sqrt{2\pi}\sigma} \quad b(x) = 1 \quad c(\sigma) = -\frac{1}{2\sigma^2} \quad d(x) = (x-\mu)^2$$

Entonces para todo m.a.s.  $x_1, x_2, \dots, x_n$  el estadístico:

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n d(x_i) = \sum_{i=1}^n (x_i - \mu)^2 \text{ es suficiente}$$

para  $\sigma$ .

• Si  $\mu$  y  $\sigma$  son desconocidos la función de densidad de la distribución normal la podemos expresar como

$$f(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x - \frac{\mu^2}{2\sigma^2}}, \text{ es decir}$$

$$f(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{\mu^2}{2\sigma^2}} \cdot e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x} \quad \text{que es}$$

de la familia exponencial ya que si consideramos  $\theta = (\mu, \sigma)$  como parámetro bidimensional

$$f(x, \theta) = a(\theta) \cdot b(x) \cdot e^{c_1(\theta) d_1(x) + c_2(\theta) d_2(x)}$$

donde:

$$a(\theta) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{\mu^2}{2\sigma^2}} \quad b(x) = 1$$

$$c_1(\theta) = -\frac{1}{2\sigma^2} \quad d_1(x) = x^2 \quad c_2(\theta) = \frac{\mu}{\sigma^2} \quad d_2(x) = x$$

De esta forma si  $x_1, x_2, \dots, x_n$  m.a.s. el estadístico:

$$T(x_1, x_2, \dots, x_n) = \left( \sum_{i=1}^n x_i, \sum_{i=1}^n x_i^2 \right) \text{ es suficiente}$$

para  $\theta = (\mu, \sigma)$

6º Un estudio urbanístico afirma que el tamaño de las ciudades con más de 200.000 habitantes tiene la siguiente función de densidad (en millones de habitantes):

$$f(x) = \begin{cases} \frac{5a}{(5x)^{a+1}} & \text{si } x > 0'2 \\ 0 & \text{en el resto} \end{cases}$$

El coeficiente  $a$  es una constante positiva básica para el cálculo de la concentración de la población en los municipios. Para su estimación se observa el tamaño de siete ciudades: 320.000, 540.000, 1.380.000, 710.000, 840.000, 2.730.000 y 450.000. Obtenga el estimador máximo verosímil y la estimación de acuerdo con la muestra seleccionada.

La función de verosimilitud es:

$$L(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f_a(x_i) = \prod_{i=1}^n \frac{5a}{(5x_i)^{a+1}} = \frac{(5a)^n}{\prod_{i=1}^n (5x_i)^{a+1}}$$

$$\ell = \ln L(x_1, x_2, \dots, x_n) = \ln \frac{(5a)^n}{\prod_{i=1}^n (5x_i)^{a+1}} = \ln(5a)^n - \ln \left[ \prod_{i=1}^n (5x_i)^{a+1} \right]$$

$$\ell = n \ln(5a) - \sum_{i=1}^n (a+1) \cdot \ln(5x_i)$$

$$\text{C.N.: } \frac{\partial \ell}{\partial a} = 0 \Rightarrow \frac{n}{a} - \sum_{i=1}^n \ln(5x_i) = 0 \Rightarrow$$

$$\Rightarrow a_{EMV} = \frac{n}{\sum_{i=1}^n \ln(5x_i)}$$

$$\text{C.S. } \frac{\partial^2 \ell}{\partial a^2} = -\frac{n}{a^2} < 0 \text{ máximo.}$$

Entonces el estimador máximo verosímil de  $a$  es:

$$a_{EMV} = \frac{n}{\sum_{i=1}^n \ln(5x_i)}$$

Si tomamos la muestra de tamaño 7 (hay que darla en millones):

$x_1 = 0'32, x_2 = 0'54, x_3 = 1'38, x_4 = 0'71, x_5 = 0'84, x_6 = 2'73, x_7 = 0'75$   
el valor máximo verosímil de  $\alpha$  es:

$$\alpha_{EMV} = \frac{7}{\ln 1'6 + \ln 2'7 + \ln 6'9 + \ln 3'55 + \ln 4'2 + \ln 13'65 + \ln 2'25}$$

es decir  $\alpha_{EMV} = \frac{7}{9'52147868} \Rightarrow \alpha_{EMV} = 0'735179926$

7º Considera una población que se distribuye según la función de densidad

$$f_\theta(x) = \begin{cases} e^{-x+\theta} & \text{si } \theta < x \\ 0 & \text{en el resto} \end{cases}$$

siendo  $\theta$  un número real cualquiera positivo. Halle la función de densidad conjunta de una m. a. s. de tamaño  $n$ . Explique, usando el criterio de factorización, porqué no podemos concluir que el estadístico  $\sum x_i$  sea un estadístico suficiente.

La función de densidad conjunta para la muestra a.s. de tamaño  $n$   $x_1, x_2, \dots, x_n$  es:

$$f_\theta(x_1, x_2, \dots, x_n) = \prod_{i=1}^n e^{-x_i+\theta} = e^{-\sum x_i + n\theta}$$

El teorema de Fisher-Neyman (criterio de factorización) dice que

$T(x_1, x_2, \dots, x_n)$  es suficiente si y sólo si

$$f_\theta(x_1, x_2, \dots, x_n) = h(x_1, x_2, \dots, x_n) \cdot g_\theta(T(x_1, x_2, \dots, x_n))$$

donde  $h(x_1, x_2, \dots, x_n)$  depende de la muestra únicamente y  $g$  depende de  $\theta$  y del valor que tome  $T$  en la muestra. En nuestro caso tenemos que:

$$g_{\theta}(T(x_1, x_2, \dots, x_n)) = e^{n\theta - \sum_{i=1}^n x_i} \quad \text{siendo}$$

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n x_i$$

$h(x_1, x_2, \dots, x_n) = 1$  que no depende de la muestra, por tanto no podemos afirmar, aplicando el principio de factorización que el estadístico  $T(x_1, x_2, \dots, x_n) = \sum x_i$  sea suficiente para  $\theta$ .

8º Supongamos una población con distribución  $p(\lambda)$  de la que se extrae una m.a.s.

a) Halle un estadístico suficiente para  $\lambda$ . ¿Qué significa ser un estadístico suficiente? ¿Para qué sirve que un estadístico lo sea?

La función de probabilidad de la distribución de Poisson es:

$$p_\lambda(x) = \frac{\lambda^x \cdot e^{-\lambda}}{x!} \quad x = 0, 1, 2, \dots$$

Como:  $p_\lambda(x) = \frac{1}{x!} e^{-\lambda} \cdot e^{x \ln \lambda}$  esta distribución pertenece a la familia exponencial ya que se puede expresar como:

$$p_\lambda(x) = a(\lambda) \cdot b(x) \cdot e^{c(\lambda)} \cdot d(x)$$

$$a(\lambda) = e^{-\lambda} \quad b(x) = \frac{1}{x!} \quad c(\lambda) = \ln \lambda \quad d(x) = x$$

Por el teorema de factorización

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n d(x_i) = \sum_{i=1}^n x_i \text{ es estadístico}$$

suficiente para  $\lambda$ .

Que  $T$  es estadístico suficiente para  $\lambda$  quiere decir que la probabilidad en una curva de nivel  $N_t = \{ (x_1, x_2, \dots, x_n) / T(x_1, x_2, \dots, x_n) = t \}$  es independiente de  $\lambda$ , es decir:

$P[x_1, x_2, \dots, x_n / T = t]$  es independiente de  $\lambda$ .  
 El que  $T$  sea un estadístico suficiente sirve para sustituir todo una muestra por un valor del estadístico  $T$ .

b) ¿Es el estadístico anterior un estimador de  $\lambda$  inservgado y consistente? Si no lo es obtenga uno que lo sea pero sin perder la condición de suficiencia. Explique intuitivamente que conllevan estas propiedades para las estimaciones que se obtengan con este estimador.

$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n x_i$  no es un estimador inservgado ya que  $E[T] = E[\sum_{i=1}^n x_i] = \sum_{i=1}^n E[x_i]$

$$E[T] = \sum_{i=1}^n \lambda = n\lambda \neq \lambda$$

El estimador  $T_1 = \frac{\sum x_i}{n} = \frac{T}{n}$  si es inservgado ya que:

$$E[T_1] = E\left[\frac{T}{n}\right] = \frac{1}{n} \cdot E[T] = \frac{1}{n} \cdot n\lambda = \lambda.$$

Además  $T_1$  es suficiente ya que  $m(x) = \frac{x}{n}$  es inyectiva y  $T_1 = m(T) = \frac{T}{n}$ .

El que  $T_1$  sea inservgado quiere decir que se approxima al valor verdadero del parámetro  $\lambda$ .

c) Calcule la cota FCR para los estimadores inservgados de  $\lambda$ . ¿Puede derivar alguna propiedad más que cumpla el estimador obtenido en b)

$$\text{cota FCR } (\lambda) = \frac{\left(\frac{\partial h(\lambda)}{\partial \lambda}\right)^2}{-n \cdot E\left[\frac{\partial^2 \ln L_\lambda(x)}{\partial \lambda^2}\right]}$$

Se tiene que  $L_\lambda(x) = P_\lambda(x) = \frac{\lambda^x \cdot e^{-\lambda}}{x!}$

$$L_\lambda(x) = \frac{1}{x!} \cdot \lambda^x \cdot e^{-\lambda} \Rightarrow \ln L_\lambda(x) = \ln\left(\frac{1}{x!}\right) + x \ln \lambda - \lambda$$

$$\frac{\partial \ln L_\lambda(x)}{\partial \lambda} = \frac{x}{\lambda} - 1$$

$$\frac{\partial^2 \ln L_\lambda(x)}{\partial \lambda^2} = -\frac{x}{\lambda^2} \Rightarrow E\left[\frac{\partial^2 \ln L_\lambda(x)}{\partial \lambda^2}\right] = E\left[-\frac{x}{\lambda^2}\right]$$

$$= -\frac{1}{\lambda^2} \cdot E[x] = -\frac{1}{\lambda^2} \cdot \lambda = -\frac{1}{\lambda}$$

Como  $h(\lambda) = \lambda \Rightarrow \frac{dh(\lambda)}{d\lambda} = 1$

luego:

$$\text{cota FCR}(\lambda) = \frac{1}{\frac{n}{\lambda}} = \frac{\lambda}{n}$$

El estimador  $T = \sum_{i=1}^n x_i$  no es eficiente ya que

$$\text{Var}[T] \neq \text{cota FCR}(\lambda) \quad x_i \text{ independientes}$$

$$\text{Var}[T] = \text{Var}\left[\sum_{i=1}^n x_i\right] = \sum_{i=1}^n \text{Var}[x_i] = \sum_{i=1}^n \lambda = n\lambda$$

El estimador  $T_1 = \frac{\sum x_i}{n}$  si es eficiente ya que

$$\text{Var}[T_1] = \text{Var}\left[\frac{\sum x_i}{n}\right] = \frac{1}{n^2} \cdot \text{Var}\left[\sum x_i\right] = \frac{1}{n^2} \cdot n\lambda$$

$\text{Var}[T_1] = \frac{\lambda}{n} = \text{cota FCR}(\lambda) \Rightarrow T_1$  eficiente ya que también es insesgado

d) Demuestre que el estimador anterior es el máximo verosímil

Sea  $x_1, x_2, \dots, x_n$  una m.a.s. entonces la función de verosimilitud es:

$$L_\lambda(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P_\lambda(x_i) = \prod_{i=1}^n \frac{\lambda^{x_i} \cdot e^{-\lambda}}{x_i!} = \frac{\lambda^{\sum x_i} \cdot e^{-n\lambda}}{\prod_{i=1}^n x_i!}$$

$$\ln L_\lambda(x_1, x_2, \dots, x_n) = \ln \frac{e^{-n\lambda} \cdot \lambda^{\sum x_i}}{\prod_{i=1}^n x_i!}$$

$$\ln L_\lambda(x_1, x_2, \dots, x_n) = -n\lambda + \sum_{i=1}^n x_i \cdot \ln \lambda - \ln \left( \prod_{i=1}^n x_i! \right)$$

$$\frac{\partial \ln L_\lambda(x_1, x_2, \dots, x_n)}{\partial \lambda} = -n + \frac{\sum x_i}{\lambda} = 0 \Rightarrow \lambda = \frac{\sum x_i}{n}$$

$$\frac{\partial^2 \ln L_\lambda(x_1, x_2, \dots, x_n)}{\partial \lambda^2} = -\frac{\sum x_i}{\lambda^2} < 0 \text{ (máximo)}$$

$$\text{Luego } \lambda_{EMV} = \frac{\sum_{i=1}^n x_i}{n} = T_1(x_1, x_2, \dots, x_n)$$

e) ¿Puede obtener alguna conclusión sobre el comportamiento asintótico del estimador? Enuncie diferentes resultados que conozca y que puedan ser utilizados para ello (tales resultados acerca de la convergencia de determinado tipo de v.v.aa como resultados a cerca de la convergencia asintótica de determinados estimadores). Indique exactamente cuál es su distribución asintótica.

Hemos visto que  $T(x_1, x_2, \dots, x_n) = \bar{x} = \frac{\sum x_i}{n}$  es insegado, consistente, eficiente y suficiente. Por el teorema central del límite tenemos que:

si  $n \rightarrow \infty \Rightarrow \bar{x} \rightsquigarrow N(\mu, \sigma)$  siendo  $\mu = E[\bar{x}] = \lambda$

$$\text{y } \sigma = \text{Var}[\bar{x}] = \sqrt{\text{cota FCR}(\lambda)} = \sqrt{\frac{\lambda}{n}}$$

Luego:

$$\lim_{n \rightarrow \infty} P(\lambda) = N\left(\lambda, \sqrt{\frac{\lambda}{n}}\right)$$

f) El número de pedidos diarios recibidos en un almacén sigue una distribución de Poisson de parámetros. En 15 días escogidos aleatoriamente, los pedidos realizados fueron: 5, 5, 11, 2, 9, 7, 2, 6, 10, 8, 6, 7, 5, 7, 10.

Aplique todo lo anterior y obtenga la estimación máximos-verosimil de  $\lambda$  en esta muestra. ¿Qué obtendría empleando correctamente el método de los momentos?

La función de verosimilitud es:

$$L_\lambda(x_1, x_2, \dots, x_n) = \prod_{i=1}^n p_\lambda(x_i) = \prod_{i=1}^n \frac{\lambda^{x_i} \cdot e^{-\lambda}}{x_i!}$$

$$L_\lambda(x_1, x_2, \dots, x_n) = \frac{1}{\prod_{i=1}^n x_i!} \cdot \lambda^{\sum x_i} \cdot e^{-n\lambda}$$

$$\ln L_\lambda(x_1, x_2, \dots, x_n) = -\ln \left( \prod_{i=1}^n x_i! \right) + \sum x_i \cdot \ln \lambda - n\lambda$$

$$\frac{\partial \ln L_\lambda(x_1, x_2, \dots, x_n)}{\partial \lambda} = \sum_{i=1}^n x_i \cdot \frac{1}{\lambda} - n = 0 \Rightarrow \lambda = \frac{\sum_{i=1}^n x_i}{n}$$

$$\frac{\partial^2 \ln L_\lambda(x_1, x_2, \dots, x_n)}{\partial \lambda^2} = -\frac{\sum_{i=1}^n x_i}{\lambda^2} < 0 \Rightarrow \text{máximo}$$

luego

$$\text{estm} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}.$$

en la muestra obtenida:

$$\text{estm} = \frac{5+5+11+\dots+10}{15} = \frac{105}{15} = 7$$

Si hubiéramos optado por estimar  $\lambda$  por el método de los momentos:

$$\lambda(\lambda) = 0 \Rightarrow E[X] = \bar{x} \Rightarrow \lambda = \bar{x} = \frac{\sum x_i}{n} \Rightarrow$$

$\Rightarrow \hat{\lambda} = \bar{x} = \frac{105}{15} = 7$ , obtendríamos el mismo resultado.

9º Un comerciante de electrodomésticos, antes de lo posible ampliación de su establecimiento en una determinada zona, quiere estudiar las posibilidades de venta que tienen sus artículos. Durante 5 semanas estudió las ventas realizadas por su comercio y obtiene los siguientes resultados en cientos de euros: 350, 270, 300, 330, 250. Supuesto que la venta sigue una distribución normal, determine las estimaciones que se obtienen tanto por el método de los momentos como por el de máxima verosimilitud, de los parámetros de la población.

• Por el método de los momentos  $\theta = (\mu, \sigma)$

$$d_1(\theta) = 0_1 \Rightarrow E[X] = \bar{x} \Rightarrow \mu = \bar{x} = 300 \Rightarrow \hat{\mu} = 300$$

$$d_2(\theta) = 0_2 \Rightarrow E[X^2] = \frac{\sum x_i^2}{n}$$

$$\text{Como } E[X^2] = \text{Var}[x] + (E[x])^2 \Rightarrow E[\bar{x}^2] = \sigma^2 + \mu^2 \\ 0_2 = s^2 + \bar{x}^2$$

$$\text{Entonces, } \sigma^2 + \mu^2 = s^2 + \cancel{\bar{x}^2} \Rightarrow \hat{\sigma} = s$$

$$\text{Al ser } s^2 = \frac{\sum x_i^2}{n} - \bar{x}^2 = 1360 \Rightarrow \hat{\sigma}^2 = 1360 \Rightarrow$$

$$\Rightarrow \hat{\sigma} = \sqrt{1360} \Rightarrow \hat{\sigma} = 36'87$$

• Por el método de máxima verosimilitud

Al ser la función de densidad de la normal

$$f_\theta(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2\sigma^2} \cdot (x-\mu)^2} \quad \text{la función de verosimilitud para la muestra } x_1, x_2, \dots, x_n \text{ es:}$$

$$L_\theta(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \frac{1}{2\sqrt{\pi}\sigma} \cdot e^{-\frac{1}{2\sigma^2} \cdot (x_i-\mu)^2}$$

es decir:

$$L_\theta(x_1, x_2, \dots, x_n) = \frac{1}{(\sqrt{2\pi}\sigma)^n} \cdot e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2}$$

Por lo tanto

$$Z = \ln L_\theta(x_1, x_2, \dots, x_n) = -n \ln(\sqrt{2\pi}\sigma) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

Máxima verosimilitud para  $\mu$

$$\frac{\partial Z}{\partial \mu} = 0 \Rightarrow +\frac{1}{2\sigma^2} \cdot 2 \sum_{i=1}^n (x_i - \mu) = 0 \Rightarrow \sum_{i=1}^n (x_i - \mu) = 0$$

$$\Rightarrow \sum_{i=1}^n x_i - \sum_{i=1}^n \mu = 0 \Rightarrow \sum_{i=1}^n x_i - n\mu = 0 \Rightarrow \mu = \frac{\sum x_i}{n}$$

$$\Rightarrow \hat{\mu} = \bar{x}$$

$$\frac{\partial^2 Z}{\partial \mu^2} = \frac{1}{\sigma^2} \cdot \sum_{i=1}^n -1 = -\frac{n}{\sigma^2} < 0 \quad (\text{máximo})$$

$$\text{dijo } \hat{\mu}_{EMV} = \bar{x} = 300$$

Máxima verosimilitud para  $\sigma$

$$\frac{\partial Z}{\partial \sigma} = -n \cdot \frac{1}{\sqrt{2\pi}\sigma} \cdot \sqrt{2\pi} + \frac{1}{\sigma^3} \sum_{i=1}^n (x_i - \mu)^2 = 0$$

$$\frac{\partial Z}{\partial \sigma} = -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum (x_i - \mu)^2 = 0$$

$$-n\sigma^2 + \sum (x_i - \mu)^2 = 0 \Rightarrow \hat{\sigma}^2 = \frac{\sum (x_i - \mu)^2}{n} = \bar{x}$$

$$\frac{\partial^2 Z}{\partial \sigma^2} = \frac{n}{\sigma^2} - \frac{3}{\sigma^4} \cdot \sum (x_i - \mu)^2$$

$$\frac{\partial^2 Z}{\partial \sigma^2} \left( \sqrt{\frac{\sum (x_i - \mu)^2}{n}} \right) = \frac{n^2}{\sum (x_i - \mu)^2} - \frac{3n^2}{\sum (x_i - \mu)^2} < 0 \quad (\text{máximo})$$

10º Considere una m.a.s. extraída de una población  $N(\mu, \sigma^2)$

- a) Calcule la cota FCR para los estimadores insegados de  $\mu$ .
- b) Demuestre que la media muestral es un estimador eficiente de la poblacional.
- c) Demuestre que la cuasivarianza muestral no es un estimador eficiente de  $\sigma^2$  sabiendo que la cota FCR para  $\sigma^2$  es  $\frac{2\sigma^4}{n}$

a) La función de verosimilitud de la normal es

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

$$Z = \ln L(x) = -\ln(\sqrt{2\pi}\sigma) - \frac{(x-\mu)^2}{2\sigma^2}$$

$$\frac{\partial Z}{\partial \mu} = \frac{x-\mu}{\sigma^2} \Rightarrow \frac{\partial^2 Z}{\partial \mu^2} = -\frac{1}{\sigma^2}$$

La cota de Fréchet - Cramér - Rao de  $\mu$  es:

$$\text{cota FCR}(\mu) = \frac{\left( \frac{\partial h(\mu)}{\partial \mu} \right)^2}{-n E\left[ \frac{\partial^2 \ln L(x)}{\partial \mu^2} \right]} \quad h(\mu) = \mu \Rightarrow \frac{\partial h(\mu)}{\partial \mu} = 1$$

Por lo tanto

$$\text{cota FCR}(\mu) = \frac{1}{\frac{n}{\sigma^2}} = \frac{\sigma^2}{n}$$

b) Si  $x_1, x_2, \dots, x_n$  es una muestra a.s. entonces

$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$  es un estimador insegado de  $\mu$  ya

que:

$$E[\bar{x}] = E\left[ \frac{\sum x_i}{n} \right] = \frac{1}{n} \cdot \sum_{i=1}^n E(x_i) = \frac{1}{n} \sum_{i=1}^n \mu = \frac{1}{n} \cdot n\mu$$

$$\Rightarrow E[\bar{x}] = \mu$$

Además

$$\text{Var}[\bar{x}] = \text{Var}\left[\frac{\sum_{i=1}^n x_i}{n}\right] = \frac{1}{n^2} \text{Var}\left[\sum_{i=1}^n x_i\right] \text{ y como}$$

los  $x_i$  son independientes

$$\text{Var}[\bar{x}] = \frac{1}{n^2} \cdot \sum_{i=1}^n \text{Var}[x_i] = \frac{1}{n^2} \cdot \sum_{i=1}^n \sigma^2 = \frac{1}{n^2} \cdot n \sigma^2 = \frac{\sigma^2}{n}$$

se verifica  $\text{var}[\bar{x}] = \text{Cota FCR}(\mu) \Rightarrow \bar{x}$  es un estimador eficiente de  $\mu \Rightarrow \bar{x}$  es eimv

c) Veamos que la cuanvarianza muestral es un estimador insesgado para la varianza poblacional

Sabemos que  $nS^2 = (n-1)S_c^2 \Rightarrow S^2 = \frac{n-1}{n} S_c^2 \Rightarrow$

$$\Rightarrow E[S^2] = \left(\frac{n-1}{n}\right) \cdot E[S_c^2]$$

la relación entre la varianza muestral y la varianza poblacional es:

$$S^2 = \frac{n-1}{n} \sigma^2$$

$$E[S^2] = \left[\frac{n-1}{n}\right] \cdot \sigma^2 \Rightarrow \cancel{\frac{n-1}{n}} \cdot E[S_c^2] = \cancel{\frac{n-1}{n}} \sigma^2 \Rightarrow$$

$$\Rightarrow E[S_c^2] = \sigma^2 \Rightarrow S_c^2 \text{ es insesgado para } \sigma^2$$

Según el lema de Fisher

$$\frac{nS^2}{\sigma^2} \sim \chi_{n-1}^2 \Rightarrow \text{Var}\left[\frac{nS^2}{\sigma^2}\right] = 2(n-1) \Rightarrow$$

$$\Rightarrow \text{Var}\left[\frac{(n-1)S_c^2}{\sigma^2}\right] = 2(n-1) \Rightarrow \frac{(n-1)^2}{\sigma^4} \text{Var}[S_c^2] = 2(n-1)$$

$$\Rightarrow \text{Var}[S_c^2] = \frac{2\sigma^4}{n-1} \neq \text{Cota FCR} = \frac{2\sigma^4}{n} \Rightarrow$$

$\Rightarrow S_c^2$  no es eficiente.

Difícil

11º Sea una m.a.s. extraída de una población con distribución exponencial de parámetro  $\alpha$  (esto es, con distribución  $G(\alpha, 1)$ )

a) Demuestre que  $\frac{n-1}{n\bar{x}} = \frac{n-1}{\sum_{i=1}^n x_i}$  es un estimador inseguro de  $\alpha$  con varianza  $\frac{\alpha^2}{n-2}$

Antes de nada recordemos la función euleriana de 1º especie o función gamma (no confundir con distribución gamma)

$$\Gamma(p) = \int_0^\infty x^{p-1} \cdot e^{-x} dx$$

$$\text{Si } n \in \mathbb{N} \Rightarrow \Gamma(n) = (n-1)!$$

Sea  $x_1, x_2, \dots, x_n$  una m.a.s. Si el estimador de  $\alpha$   $T(x_1, x_2, \dots, x_n) = \frac{n-1}{\sum_{i=1}^n x_i}$  es inseguro entonces se

debe cumplir que  $E[T] = E\left[\frac{n-1}{\sum x_i}\right] = (n-1)E\left[\frac{1}{\sum x_i}\right] = \alpha$

El problema es que no sabemos como se distribuye

$\frac{1}{\sum_{i=1}^n x_i}$ , tan solo sabemos que  $x_i \sim \text{Exp}(\alpha) = G(\alpha, 1)$

Como  $G(\alpha, 1)$  es reproductiva si  $x_i \sim G(\alpha, 1) \Rightarrow$

$\Rightarrow Y = \sum_{i=1}^n x_i \sim G(\alpha, n)$ . Por lo tanto podemos

saber que  $E\left[\frac{1}{Y}\right] = \int_{-\infty}^{\infty} \frac{1}{y} \cdot f(y) dy$  donde  $f$  es

la función de densidad de  $G(\alpha, n)$

$$f(y) = \begin{cases} \frac{\alpha^n}{\Gamma(n)} \cdot e^{-\alpha y} \cdot y^{n-1} & \text{si } y > 0 \\ 0 & \text{en el resto} \end{cases}$$

Entonces

$$E\left[\frac{1}{y}\right] = \int_0^\infty \frac{1}{y} \cdot \frac{\alpha^n}{\Gamma(n)} \cdot e^{-\alpha y} \cdot y^{n-1} dy$$

$$E\left[\frac{1}{y}\right] = \frac{\alpha^n}{\Gamma(n)} \int_0^\infty y^{n-2} \cdot e^{-\alpha y} dy \quad \left\{ \begin{array}{l} t = \alpha y \Rightarrow y = \frac{t}{\alpha} \\ dy = \frac{1}{\alpha} dt \end{array} \right\}$$

$$E\left[\frac{1}{y}\right] = \frac{\alpha^n}{\Gamma(n)} \int_0^\infty \left(\frac{t}{\alpha}\right)^{n-2} \cdot e^{-t} \cdot \frac{1}{\alpha} dt = \frac{\alpha}{\Gamma(n)} \int_0^\infty t^{(n-1)-1} \cdot e^{-t} dt =$$
$$= \frac{\alpha}{\Gamma(n)} \cdot \Gamma(n-1) = \frac{\alpha}{(n-1)!} \cdot (n-1)! = \frac{\alpha}{n-1}$$

Por lo tanto  $E\left[\frac{1}{\sum_{i=1}^n x_i}\right] = \frac{\alpha}{n-1}$

luego:

$$E[T(x_1, x_2, \dots, x_n)] = (n-1) \cdot E\left[\frac{1}{\sum_{i=1}^n x_i}\right] = (n-1) \cdot \frac{\alpha}{n-1} = \alpha$$

$$\Rightarrow T(x_1, x_2, \dots, x_n) = \frac{n-1}{\sum_{i=1}^n x_i} \text{ es estimador inservado de } \alpha.$$

Para obtener la varianza de  $T(x_1, \dots, x_n) = \frac{n-1}{\sum_{i=1}^n x_i}$ :

$$\text{Var}[T] = \text{Var}\left[\frac{n-1}{\sum_{i=1}^n x_i}\right] = (n-1)^2 \text{Var}\left[\frac{1}{y}\right] \text{ y } y \sim G(\alpha, n)$$

$$\text{Var}\left[\frac{1}{y}\right] = E\left[\left(\frac{1}{y}\right)^2\right] - \left[E\left[\frac{1}{y}\right]\right]^2$$

$$E\left[\frac{1}{y^2}\right] = \int_0^\infty \frac{\alpha^n}{\Gamma(n)} \cdot e^{-\alpha y} \cdot y^{n-1} \cdot \frac{1}{y^2} dy =$$

$$E\left[\frac{1}{y^2}\right] = \frac{\alpha^n}{\Gamma(n)} \cdot \int_0^\infty e^{-\alpha y} \cdot y^{n-3} dy \quad \left\{ \begin{array}{l} t = \alpha y \\ y = \frac{t}{\alpha} \\ dy = \frac{1}{\alpha} dt \end{array} \right\}$$

$$E\left[\frac{1}{y^2}\right] = \frac{\alpha^n}{\Gamma(n)} \cdot \int_0^\infty \left(\frac{t}{\alpha}\right)^{n-3} \cdot e^{-t} \cdot \frac{1}{\alpha} dt =$$

$$E\left[\frac{1}{y^2}\right] = \frac{\alpha^2}{\Gamma(n)} \int_0^\infty t^{n-3} \cdot e^{-t} dt = \frac{\alpha^2}{\Gamma(n)} \int_0^\infty t^{(n-2)-1} \cdot e^{-t} dt$$

$$E\left[\frac{1}{y^2}\right] = \frac{\alpha^2}{\Gamma(n)} \cdot \Gamma(n-2) \quad \text{con lo que}$$

$$E\left[\frac{1}{y^2}\right] = \frac{\alpha^2}{(n-1)!} \cdot (n-3)! = \frac{\alpha^2 \cdot (n-3)(n-2) \cdots 2 \cdot 1}{(n-1)(n-2)(n-3) \cdots 2 \cdot 1}$$

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

Entonces:

$$\text{Var}\left[\frac{1}{y}\right] = E\left[\left(\frac{1}{y}\right)^2\right] - \left(E\left[\frac{1}{y}\right]\right)^2$$

$$\text{Var}\left[\frac{1}{y}\right] = \frac{\alpha^2}{(n-1)(n-2)} - \frac{\alpha^2}{(n-1)^2} = \frac{\alpha^2(n-1) - \alpha^2(n-2)}{(n-1)^2(n-2)}$$

$$\text{Var}\left[\frac{1}{y}\right] = \frac{\cancel{\alpha^2 n} - \cancel{\alpha^2} - \cancel{\alpha^2 n} + 2\cancel{\alpha^2}}{(n-1)^2 \cdot (n-2)} = \frac{\alpha^2}{(n-1)^2(n-2)}$$

Entonces:

$$\text{Var}[T] = (n-1)^2 \cdot \text{Var}\left[\frac{1}{y}\right] = \frac{\alpha^2}{n-2}$$

b) Demuestre que la cota FCR de  $\alpha$  vale  $\frac{\alpha^2}{n}$

la cota  $\text{Cota FCR}(\alpha)$  vale:

$$\text{Cota FCR}(\theta) = \frac{\left(\frac{d h(\theta)}{d \theta}\right)^2}{-n E\left[\frac{\partial^2 \ln L_\theta(x)}{\partial \theta^2}\right]}$$

$$\text{Como } h(\alpha) = \alpha \Rightarrow \frac{d h(\alpha)}{d \alpha} = 1.$$

da función de verosimilitud de la exponencial de parámetro  $\alpha$  vale:

$$L_\alpha(x) = \alpha \cdot e^{-\alpha x}$$

$$\ln L_\alpha(x) = \ln \alpha - \alpha x$$

$$\frac{\partial \ln L_\alpha(x)}{\partial \alpha} = \frac{1}{\alpha} - x \Rightarrow \frac{\partial^2 \ln L_\alpha(x)}{\partial \alpha^2} = -\frac{1}{\alpha^2}$$

sigue:

$$\text{Cota FCR}(\alpha) = \frac{1}{n \cdot E[-\frac{1}{\alpha^2}]} = \frac{\alpha^2}{n}$$

c) Sabiendo que se puede demostrar que el estimador indicado anteriormente es el estimador inscogido de mínima varianza, ¿qué concluiría acerca del teorema de FCR aplicado a esta situación?

Se verifica que  $\text{Cota FCR}(\alpha) \leq \text{Var}[T]$  ya que

$$\frac{\alpha^2}{n} \leq \frac{\alpha^2}{n-2} = \text{Var}[T]$$

El teorema se cumple, lo que pasa es que no se alcanza la cota FCR

d) En unas pruebas para determinar la distribución de tiempo de vida de unas rotativas se obtienen los siguientes resultados medidos en meses: 9, 15, 8, 25, 6, 17, 23, 5. Si se piensa que la distribución de esa variable se ajusta a un modelo exponencial de parámetro  $\alpha$ , estime este mediante el método de los momentos y el de máxima verosimilitud.

Método de los momentos

$$\alpha_1(\alpha) = 0_1 \Rightarrow E[X] = \bar{x} \Rightarrow \frac{1}{\lambda} = \bar{x} \Rightarrow \lambda = \frac{1}{\bar{x}} \Rightarrow$$

$$\Rightarrow \hat{\lambda} = \frac{n}{\sum_{i=1}^n x_i} = \frac{8}{108} = 0'074.$$

Método de máxima verosimilitud.

La función de verosimilitud es

$$L(\alpha | x_1, x_2, \dots, x_n) = \prod_{i=1}^n \lambda \cdot e^{-\lambda x_i} = \lambda^n \cdot e^{-\lambda \sum_{i=1}^n x_i}$$

$$\ln L(\alpha | x_1, x_2, \dots, x_n) = n \ln \lambda - \lambda \cdot \sum_{i=1}^n x_i$$

$$\frac{\partial \ln L(\alpha)}{\partial \lambda} = \frac{n}{\lambda} - \sum_{i=1}^n x_i = 0 \Rightarrow \hat{\lambda} = \frac{n}{\sum_{i=1}^n x_i}$$

$$\frac{\partial^2 \ln L(\alpha)}{\partial \lambda^2} = -\frac{n}{\lambda^2} < 0 \text{ máximo.}$$

de modo

$$\hat{\lambda}_{EMV} = \frac{n}{\sum_{i=1}^n x_i} = \frac{8}{108} = 0'074.$$

e) Compruebe que el estimador máximo verosimil que obtuvo en d) no es igual al estimador de a) de que sabemos acerca del comportamiento asintótico del estimador máximo-verosimil nos lleva a asegurar que su varianza se aproxima en el infinito a la cota FCR por lo que podría llegar un momento en el que su varianza fuera menor que la del estimador de a). ¿Entraría esta última afirmación en contradicción con lo que se afirmó en c) acerca de cuál es el estimador inscogido de mínima varianza?

El estimador del apartado a) es  $\hat{\lambda} = \frac{n-1}{\sum_{i=1}^n x_i}$  y el del apartado d) es  $\hat{\lambda}_{EMV} = \frac{n}{\sum_{i=1}^n x_i}$

$$\text{Se cumple que } \text{Var}[\hat{\lambda}] < \text{Var}[\hat{\lambda}_{EMV}]$$

Sabemos por apartados anteriores que:

$$\text{Var} \left[ \frac{1}{\sum_{i=1}^n x_i} \right] = \frac{\alpha^2}{(n-1)^2(n-2)} \quad \text{Entonces:}$$

$$\text{Var} [\hat{\alpha}_{EMV}] = \text{Var} \left[ \frac{n}{\sum_{i=1}^n x_i} \right] = n^2 \cdot \frac{\alpha^2}{(n-1)^2(n-2)}$$

$$\text{Var} [\hat{\alpha}_{EMV}] = \frac{n^2}{(n-1)^2} \cdot \text{Var} [\hat{\alpha}]$$

$$\text{Como } \frac{n^2}{(n-1)^2} > 1 \Rightarrow \text{Var} [\hat{\alpha}_{EMV}] > \text{Var} [\hat{\alpha}].$$

$$\lim_{n \rightarrow \infty} \text{Var} [\hat{\alpha}_{EMV}] = \lim_{n \rightarrow \infty} \frac{n^2}{(n-1)^2} \text{Var} [\hat{\alpha}] = \text{Var} [\hat{\alpha}]$$

A pesar de que para  $n \rightarrow \infty$  los valores de la varianza del estimador  $\hat{\alpha}$  del apartado a) y el de  $\hat{\alpha}_{EMV}$  coinciden, está claro que siempre se verifica que  $\text{Var} [\hat{\alpha}_{EMV}] = \text{Var} [\hat{\alpha}]$ , no hay posibilidad de imprimir el Teorema de Fréchet - Cramér - Rao.

12) Considera una población  $u(0, \theta)$  definida para  $\theta > 0$ .

a) Demuestre que el estadístico  $\frac{n+1}{n} \max \{x_1, x_2, \dots, x_n\}$  definido a partir de una m.a.s es inscogido de  $\theta$  y tiene una varianza igual a  $\frac{\theta^2}{n(n+2)}$

b) Calcule la cota de FCR. ¿Se viola en este caso la tesis del teorema correspondiente? En caso afirmativo, ¿cuál es la razón de que esto ocurra?

Vamos a calcular la función de densidad de

$T(x_1, x_2, \dots, x_n) = \max \{x_1, x_2, \dots, x_n\}$ . Recordemos que la función de densidad de  $X$  es:

$$\curvearrowleft f_X(x) = \begin{cases} \frac{1}{\theta} & \text{si } 0 < x < \theta \\ 0 & \text{en el resto} \end{cases}$$

La función de distribución de  $T$  es:

$$F_T(t) = P[T < t] = P[\max\{x_1, x_2, \dots, x_n\} < t] =$$

=  $P[x_1 < t, x_2 < t, \dots, x_n < t]$ . Como las  $x_i$  son independientes:

$$F_T(t) = \prod_{i=1}^n P[x_i < t] = \prod_{i=1}^n \left[ \int_0^t \frac{1}{\theta} dt \right] \quad \text{si } 0 < t < \theta$$

$$\curvearrowleft F_T(t) = \prod_{i=1}^n \frac{t}{\theta} = \left( \frac{t}{\theta} \right)^n \quad \text{si } 0 < t < \theta$$

desde la función de densidad de  $T$  es:

$$f_T(t) = \begin{cases} n \cdot \frac{t^{n-1}}{\theta^n} \cdot \frac{1}{\theta} & \text{si } 0 < t < \theta \\ 0 & \text{en el resto} \end{cases}$$

$$f_T(t) = F'_T(t) = \begin{cases} \frac{n}{\theta^n} \cdot t^{n-1} & \text{si } 0 < t < \theta \\ 0 & \text{en el resto.} \end{cases}$$

$$\curvearrowleft E[T] = \int_0^\theta t \cdot \frac{n}{\theta^n} \cdot t^{n-1} dt = \frac{n}{\theta^n} \cdot \int_0^\theta t^n dt$$

$$E[T] = \frac{n}{\theta^n} \cdot \left[ \frac{t^{n+1}}{n+1} \right]_0^\theta = \frac{n}{\theta^n} \cdot \frac{\theta^{n+1}}{n+1} = \frac{n\theta}{n+1}$$

Se tiene que:

$$E\left[\frac{n+1}{n} \cdot \max\{x_1, x_2, \dots, x_n\}\right] = \frac{n+1}{n} \cdot E[T] = \frac{n+1}{n} \cdot \frac{n\theta}{n+1} = \theta$$

$\Rightarrow \frac{n+1}{n} \cdot \max\{x_1, x_2, \dots, x_n\}$  es inservido para  $\theta$ .

Hallemos ahora la varianza de  $T = \max\{x_1, x_2, \dots, x_n\}$

$$\text{Var}[T] = E[T^2] - (E[T])^2$$

$$E[T^2] = \int_{-\infty}^{\infty} t^2 \cdot f(t) dt = \int_0^{\theta} \frac{n}{\theta^n} \cdot t^{n-1} \cdot t^2 dt$$

$$E[T^2] = \frac{n}{\theta^n} \cdot \int_0^{\theta} t^{n+1} dt = \frac{n}{\theta^n} \cdot \frac{t^{n+2}}{n+2} \Big|_0^{\theta}$$

$$E[T^2] = \frac{n \cdot \theta^{n+2}}{\theta^n \cdot (n+2)} = \frac{n \cdot \theta^2}{n+2}$$

demos  $\text{Var}[T] = \frac{n \cdot \theta^2}{n+2} + \left(\frac{n \theta}{n+1}\right)^2 = \frac{n \theta^2}{n+2} + \frac{n^2 \theta^2}{(n+1)^2}$

Entonces

$$\text{Var}\left[\frac{n+1}{n} \cdot \max\{x_1, x_2, \dots, x_n\}\right] = \frac{(n+1)^2}{n^2} \cdot \text{Var}[T]$$

$$\text{Var}\left[\frac{n+1}{n} \max\{x_1, x_2, \dots, x_n\}\right] = \frac{(n+1)^2}{n^2} \cdot \left[\frac{n \theta^2}{n+2} - \frac{n^2 \theta^2}{(n+1)^2}\right]$$

$$\text{Var}\left[\frac{n+1}{n} \cdot \max\{x_1, x_2, \dots, x_n\}\right] = \frac{(n+1)^2 \cdot \theta^2}{n(n+2)} - \theta^2 = \frac{\theta^2}{n(n+2)}$$

b)  $\left(\frac{\partial h(\theta)}{\partial \theta}\right)^2$

$$\text{Cota FCR} = \frac{-n \cdot E\left[\frac{\partial^2 \ln L_\theta(x)}{\partial \theta^2}\right]}{-n \cdot E\left[\frac{\partial \ln L_\theta(x)}{\partial \theta}\right]}$$

En este caso  $h(\theta) = \theta \Rightarrow \frac{\partial h(\theta)}{\partial \theta} = 1$

$$L_\theta(x) = \frac{1}{\theta} \Rightarrow \ln L_\theta(x) = \ln \frac{1}{\theta} = -\ln \theta$$

$$\frac{\partial \ln L_\theta(x)}{\partial \theta} = -\frac{1}{\theta} \Rightarrow \frac{\partial^2 \ln L_\theta(x)}{\partial \theta^2} = \frac{1}{\theta^2}$$

Entonces:

$$\text{cota FCR}(\theta) = \frac{1}{-n \cdot \frac{1}{\theta^2}} = -\frac{\theta^2}{n}$$

No se puede aplicar el T.FCR ya que no se cumplen las condiciones de regularidad al

depender el campo de variación de  $x$  del parámetro  $\theta$

13 Sea una m.a.s. de una v.a. uniforme en el intervalo  $(\theta - \frac{1}{2}, \theta + \frac{1}{2})$ . ¿ Se puede decir que el estimador máximo-verosímil de  $\theta$  está bien definido en este caso ?

La función de densidad de  $u(\theta - \frac{1}{2}, \theta + \frac{1}{2})$  es

$$f_x(x) = \begin{cases} 1 & \text{si } \theta - \frac{1}{2} < x < \theta + \frac{1}{2} \\ 0 & \text{en el resto} \end{cases}$$

La función de verosimilitud es entonces  $L_\theta(x) = 1 \Rightarrow z = \ln L_\theta(x) = 0$ . Esta función es constante, su valor máximo sería cualquier valor de  $x$  comprendido entre  $\theta - \frac{1}{2}$  y  $\theta + \frac{1}{2}$ . El estimador máximo verosímil de  $\theta$  no está bien definido por no ser único.

14º La demanda de automóviles de una determinada marca es una v.a. discreta con función de probabilidad:

$$P_\theta(x=x) = \theta \cdot (1-\theta)^{x-1} \text{ si } x=1, 2, \dots \text{ con } 0 < \theta < 1.$$

Con objeto de satisfacer el mayor número de clientes posibles, interesa conocer  $\theta$ , para lo que se realiza un muestreo entre 7 concesionarios de dicha marca. Los resultados son los siguientes (expresados en número de automóviles): 8, 9, 5, 4, 10, 6, 7. Estimar valores para  $\theta$  empleando para ello tanto el método de los momentos como el máximo-verosímil

Método de los momentos

$$\alpha_1(\theta) = 0, \Rightarrow E[\bar{x}] = \bar{x}$$

$$E[\bar{x}] = \sum_{i=1}^{\infty} x_i \cdot P(x=x_i) = \sum_{i=1}^{\infty} x_i \cdot \theta \cdot (1-\theta)^{x_i-1}$$

$$E[\bar{x}] = \theta \cdot \sum_{i=1}^{\infty} x_i (1-\theta)^{x_i-1}$$

Como  $x = 1, 2, 3, \dots$  podemos tomar  $x_i = i$  de modo que

$$\sum_{i=1}^{\infty} x_i (1-\theta)^{x_i-1} = \sum_{x_i=1}^{\infty} x_i (1-\theta)^{x_i-1} = \sum_{x=1}^{\infty} x (1-\theta)^{x-1}$$

Veamos como se suma esta serie

Como  $|1-\theta| < 1$  ya que  $0 < \theta < 1$   $\sum_{x=1}^{\infty} (1-\theta)^x$  es

una serie geométrica convergente cuya suma vale:

$$\sum_{x=1}^{\infty} (1-\theta)^x = \frac{1-\theta}{1-(1-\theta)} = \frac{1-\theta}{\theta}$$

Si derivamos respecto a  $\theta$  y teniendo en cuenta que la derivada de una suma es igual a la suma de las derivadas:

$$\frac{d}{d\theta} \left( \sum_{x=1}^{\infty} (1-\theta)^x \right) = \frac{d}{d\theta} \left( \frac{1-\theta}{\theta} \right)$$

$$-\sum_{x=1}^{\infty} x (1-\theta)^{x-1} = \frac{-\theta - (1-\theta)}{\theta^2} = \frac{-1}{\theta^2} \Rightarrow$$

$$\Rightarrow \sum_{x=1}^{\infty} x (1-\theta)^{x-1} = \frac{1}{\theta^2}$$

luego:

$$\alpha_1(\theta) = E[X] = \theta \cdot \sum_{i=1}^{\infty} x_i (1-\theta)^{x_i-1} = \theta \cdot \frac{1}{\theta^2} = \frac{1}{\theta}$$

$$\text{Entonces } \alpha_1(\theta) = 0, \Rightarrow \frac{1}{\theta} = \bar{x} \Rightarrow \theta = \frac{1}{\bar{x}} \Rightarrow$$

$$\Rightarrow \hat{\theta} = \frac{n}{\sum_{i=1}^n x_i} \quad \text{En nuestro caso, con la muestra de tamaño 7 tenemos}$$

$$\hat{\theta} = \frac{7}{49} = \frac{1}{7}$$

Ahora vamos a estimar  $\theta$  por el método de máxima verosimilitud

$$P_\theta(X=x) = \theta \cdot (1-\theta)^{x-1} \quad x=1, 2, 3, \dots \quad 0 < \theta < 1.$$

La función de verosimilitud de la m.a.s.  $x_1, x_2, \dots, x_n$  es:

$$L_\theta(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \theta \cdot (1-\theta)^{x_i-1}$$

$$\ell = \ln L_\theta(x_1, x_2, \dots, x_n) = \sum_{i=1}^n \ln \theta + (x_i - 1) \cdot \ln(1-\theta)$$

$$\frac{\partial \ell}{\partial \theta} = \sum_{i=1}^n \frac{1}{\theta} + \frac{x_i - 1}{1-\theta} (-1) = \frac{n}{\theta} - \frac{1}{1-\theta} \cdot \sum_{i=1}^n (x_i - 1) = 0$$

$$\frac{n}{\theta} = \frac{1}{1-\theta} \cdot \sum_{i=1}^n (x_i - 1)$$

$$n - n\theta = \theta \sum_{i=1}^n (x_i - 1)$$

$$(n + \sum_{i=1}^n (x_i - 1))\theta = n \Rightarrow \theta = \frac{n}{n + \sum_{i=1}^n (x_i - 1)}$$

$$\frac{\partial^2 \ell}{\partial \theta^2} = -\frac{n}{\theta^2} - \frac{1}{(1-\theta)^2} \sum_{i=1}^n (x_i - 1) < 0 \text{ máximo.}$$

Demuestro:

$$\hat{\theta}_{EMV} = \frac{n}{n + \sum_{i=1}^n (x_i - 1)}$$

En nuestro caso:

$$\hat{\theta}_{EMV} = \frac{7}{7+42} = \frac{7}{49} = \frac{1}{7}$$

15-a) Defina correctamente los tres conceptos siguientes: parámetro poblacional, estadístico muestral, estimador y estimación.

\* Parámetro poblacional: es un valor asociado a una población, conocido o no, que aparece en la función de probabilidad o densidad de la población.

Por ejemplo si  $X = \text{nº de caras que aparecen en el lanzamiento de una moneda}$  que puede estar cara o cruz.  $X$  puede tomar el valor 0 ó el valor 1. Si  $p$  es la probabilidad de obtener cara (no tiene por qué ser  $\frac{1}{2}$ )  $\Rightarrow (1-p)$  es la probabilidad de obtener cruz. La función de probabilidad es:

$$P[X=x] = p^x \cdot (1-p)^{1-x} = \left(\frac{p}{1-p}\right)^x \cdot (1-p)$$

El parámetro de la población es  $p$  en este caso.

\* Estadístico muestral: si consideramos la muestra de tamaños  $n \{x_1, x_2, \dots, x_n\}$  como una variable aleatoria  $n$ -dimensional  $(x_1, x_2, \dots, x_n)$  el estadístico muestral es cualquier función en la forma:

$$\begin{aligned} T: \mathbb{R}^n &\longrightarrow \mathbb{R} \\ (x_1, x_2, \dots, x_n) &\rightarrow T(x_1, x_2, \dots, x_n) \end{aligned}$$

\* Estimador: es un estadístico muestral  $T: \mathbb{R}^n \rightarrow \mathbb{R}$  que verifica que su campo de variación (conjunto de valores que puede tomar  $T$ , es decir el conjunto  $\{t \in \mathbb{R} / T(x_1, x_2, \dots, x_n) = t\}$ ) está contenido en el espacio paramétrico (conjunto de valores que puede tomar el parámetro).

\* Estimación: es el valor que toma el estimador en una realización muestral.

b) Se analizan dos variables normales  $x$  e  $y$  con medias distintas  $\mu_1$  y  $\mu_2$  respectivamente y con la misma varianza  $\sigma^2$

Se toman sendas m.m. a.s.s. independientes de ambas, las dos de igual tamaño  $x_1, x_2, \dots, x_n$  e  $y_1, y_2, \dots, y_n$ . Conteste a las siguientes preguntas razonando sus respuestas:

b) ¿Es la diferencia entre las dos medias muestrales un estimador insesgado y consistente de alguna cantidad poblacional? ¿de cuál? Demuestre y comente el resultado señalando las implicaciones que la consistencia e insesgadez tiene sobre el comportamiento de cualquier estimador.

$$\text{Si } x_i \sim N(\mu_1, \sigma^2) \Rightarrow \bar{x} \sim N(\mu_1, \frac{\sigma^2}{n})$$

$$y \sim N(\mu_2, \sigma^2) \Rightarrow \bar{y} \sim N(\mu_2, \frac{\sigma^2}{n})$$

Como la distribución normal es reproductiva se verifica que  $\bar{x} - \bar{y} \sim N(\mu_1 - \mu_2, \frac{\sigma^2}{n})$ . Por tanto

$E[\bar{x} - \bar{y}] = \mu_1 - \mu_2 = E[\bar{x}] - E[\bar{y}]$ , es un estimador insesgado de diferencia de medias para la media poblacional.

Además  $T(x, y) = \bar{x} - \bar{y}$  es consistente en media cuadrática ya que:

$$\lim_{n \rightarrow \infty} ECM(\bar{x} - \bar{y}) = 0, \text{ porque es insesgado}$$

$\lim_{n \rightarrow \infty} [E[\bar{x} - \bar{y}] - (\mu_1 - \mu_2)] = 0$  (bastaría con que fuese asintóticamente insesgado) y  $\lim_{n \rightarrow \infty} \text{Var}[\bar{x} - \bar{y}] = 0$

$$\text{ya que } \text{Var}[\bar{x} - \bar{y}] = \frac{\sigma^2}{n} \Rightarrow \lim_{n \rightarrow \infty} \text{Var}[\bar{x} - \bar{y}] = 0$$

$$\text{Al ser } ECM[\bar{x} - \bar{y}] = \text{Var}[\bar{x} - \bar{y}] + (E[\bar{x} - \bar{y}] - (\mu_1 - \mu_2))^2$$

$$\Rightarrow \lim_{n \rightarrow \infty} ECM[\bar{x} - \bar{y}] = 0$$

Si el estimador es insesgado no garantiza que la esperanza (media poblacional) de ese estimador va a coincidir con el valor del parámetro en la

población, es decir, que si tomáramos muchas muestras y estimáramos en cada una de ellas el parámetro poblacional, la media de esas estimaciones coincidiría con el parámetro poblacional.

Si el estimador es consistente en media cuadrática quiere decir que se comete poco error cuando se sustituye el valor estimado por el verdadero valor de la población que es desconocido.

b) Con el fin de estimar la varianza poblacional, es apropiado emplear la información de las dos muestras de manera combinada. Por ello se proponen los siguientes estimadores alternativos:

$$T_1 = \frac{S_{cx}^2 + S_{cy}^2}{2} \quad T_2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^n (y_i - \bar{y})^2}{2n-1}$$

Indique si cada uno de ellos es inserviable y cual de los dos tiene menor varianza.

Según el lema de Fisher

$$\frac{(n-1)}{\sigma^2} S_{cx}^2 \sim \chi_{n-1}^2, \quad \frac{(n-1)}{\sigma^2} S_{cy}^2 \sim \chi_{n-1}^2$$

Al ser la distribución  $\chi^2$ -cuadrado reproductiva

$$\frac{n-1}{\sigma^2} S_{cx}^2 + \frac{n-1}{\sigma^2} S_{cy}^2 \sim \chi_{2(n-1)}^2 \text{ y por lo tanto}$$

$$\text{Var} \left[ \frac{n-1}{\sigma^2} S_{cx}^2 + \frac{n-1}{\sigma^2} S_{cy}^2 \right] = 2 \cdot [2(n-1)] = 4(n-1)$$

Luego:

$$\text{Var} \left[ \frac{n-1}{\sigma^2} (S_{cx}^2 + S_{cy}^2) \right] = 4(n-1) \Rightarrow \frac{(n-1)^2}{\sigma^4} \text{Var}[S_{cx}^2 + S_{cy}^2] =$$

=  $4(n-1)$  con lo que:

$$\text{Var}[S_{cx}^2 + S_{cy}^2] = \frac{4(n-1) \cdot \sigma^4}{(n-1)^2} = \frac{4\sigma^4}{n-1}$$

$$\text{Var}[S_{cx}^2 + S_{cy}^2] = \frac{4\sigma^4}{n-1} \Rightarrow \text{Var} \left[ \frac{S_{cx}^2 + S_{cy}^2}{2} \right] = \frac{\sigma^4}{n-1}$$

$$\text{Como } s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \Rightarrow \sum_{i=1}^n (x_i - \bar{x})^2 = n s_x^2$$

$$\text{De igual forma } \sum_{i=1}^n (y_i - \bar{y})^2 = n \cdot s_y^2$$

$$\text{Ademáis sabemos que } \frac{n s_x^2}{\sigma^2} \sim \chi_{n-1}^2 \quad \frac{n s_y^2}{\sigma^2} \sim \chi_{n-1}^2$$

$$\frac{n}{\sigma^2} (s_x^2 + s_y^2) \sim \chi_{2(n-1)}^2$$

$$\text{Var} \left[ \frac{n}{\sigma^2} (s_x^2 + s_y^2) \right] = 4(n-1)$$

$$\frac{n^2}{\sigma^4} \text{Var}[s_x^2 + s_y^2] = 4(n-1) \Rightarrow \text{Var}[s_x^2 + s_y^2] = \frac{4(n-1)\sigma^4}{n^2}$$

Tenemos que:

$$\text{Var} \left[ \frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^n (y_i - \bar{y})^2}{2n-1} \right] = \text{Var} \left[ \frac{n s_x^2 + n s_y^2}{2n-1} \right] =$$

$$= \text{Var} \left[ \frac{n}{2n-1} (s_x^2 + s_y^2) \right] = \frac{n^2}{(2n-1)^2} \text{Var}[s_x^2 + s_y^2] =$$

$$= \frac{n^2}{(2n-1)^2} \cdot \frac{4(n-1) \cdot \sigma^4}{n^2} = \frac{4(n-1) \sigma^4}{(2n-1)^2}$$

El estimador  $s_{cx}^2 + s_{cy}^2$  tiene menor varianza que el estimador:

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^n (y_i - \bar{y})^2}{2n-1}$$

$$\text{ya que } \frac{\sigma^4}{n-1} < \frac{4(n-1) \sigma^4}{(2n-1)^2} \text{ para } n > 9.$$

según hemos visto  $\frac{n-1}{\sigma^2} (S_{cx}^2 + S_{cy}^2) \sim \chi^2_{2(n-1)}$

Por tanto :

$$E \left[ \frac{n-1}{\sigma^2} (S_{cx}^2 + S_{cy}^2) \right] = 2(n-1)$$

$$\frac{n-1}{\sigma^2} \cdot E [S_{cx}^2 + S_{cy}^2] = 2(n-1) \Rightarrow E [S_{cx}^2 + S_{cy}^2] = 2\sigma^2 \Rightarrow$$

$$\Rightarrow E \left[ \frac{S_{cx}^2 + S_{cy}^2}{2} \right] = \frac{1}{2} E [S_{cx}^2 + S_{cy}^2] = \frac{1}{2} \cdot 2\sigma^2 = \sigma^2$$

Por tanto el estimador  $\frac{S_{cx}^2 + S_{cy}^2}{2}$  es inservado para  $\sigma^2$ .

Según hemos visto anteriormente :

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^n (y_i - \bar{y})^2}{2n-2} = \frac{n S_x^2 + n S_y^2}{2n-2} \Rightarrow$$

$$\Rightarrow E \left[ \frac{n S_x^2 + n S_y^2}{2n-2} \right] = \frac{n}{2n-2} \cdot E [S_x^2 + S_y^2]$$

$$\text{Como } \frac{n}{\sigma^2} (S_x^2 + S_y^2) \sim \chi^2_{2(n-2)}$$

$$E \left[ \frac{n}{\sigma^2} (S_x^2 + S_y^2) \right] = \frac{n}{\sigma^2} \cdot E [S_x^2 + S_y^2] = 2(n-2)$$

$$\Rightarrow E [S_x^2 + S_y^2] = \frac{2(n-2) \cdot \sigma^2}{n} . \text{ Entonces :}$$

$$E \left[ \frac{\sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^n (y_i - \bar{y})^2}{2n-2} \right] = \frac{n}{2n-2} \cdot \frac{2(n-2)}{n} \cdot \sigma^2 =$$

$$= \frac{2(n-1) \cdot \sigma^2}{2n-2} \neq \sigma^2 \text{ no es inservido pero si lo}$$

es asintóticamente ya que  $\lim_{n \rightarrow \infty} \frac{2(n-1) \sigma^2}{2n-2} = \sigma^2$ .

16º Considera la familia de distribuciones  $B(n, p)$  con  $n$  fija y conocida. ¿Es una familia exponencial?

Las distribuciones de la familia exponencial tienen como función de probabilidad o densidad las de la forma

$$f_\theta(x) \text{ ó } P_\theta(x) = a(\theta) \cdot b(x) \cdot e^{c(\theta) \cdot d(x)}, \text{ siendo } \theta$$

el parámetro de la distribución,  $a(\theta)$  y  $c(\theta)$  son dos funciones que tan sólo dependen de  $\theta$ ,  $b(x)$  y  $d(x)$  son funciones que tan sólo dependen de  $x$ .

La función de probabilidad de la binomial  $B(n, p)$  es:

$$P[X=x] = \binom{n}{x} p^x \cdot (1-p)^{n-x} = \binom{n}{x} p^x \cdot \frac{(1-p)^n}{(1-p)^x}$$

$$P[X=x] = \binom{n}{x} \cdot \left(\frac{p}{1-p}\right)^x \cdot (1-p)^n = \binom{n}{x} \cdot (1-p)^n \cdot e^{\ln\left(\frac{p}{1-p}\right)x}$$

siglo:

$$P[X=x] = \binom{n}{x} \cdot (1-p)^n \cdot e^{\ln\left(\frac{p}{1-p}\right) \cdot x}$$

$$a(p) = (1-p)^n \quad b(x) = \binom{n}{x} \quad c(p) = \ln \frac{p}{1-p} \quad d(x) = x$$

siglo la binomial  $B(n, p)$  pertenece a la familia exponencial.

17º Al promedio de averías de una máquina se ha adaptado la siguiente densidad gamma:

$$f_\beta(x) = \begin{cases} \frac{1}{24} x^4 \beta^{-5} \cdot e^{-\frac{x}{\beta}} & \text{si } x > 0 \\ 0 & \text{en el resto} \end{cases}$$

El parámetro  $\beta$  es una constante positiva de valor desconocido clave para la correcta especificación y se pide por ello su estimación máxima-verosimil para una muestra de tamaño  $n$ . Compruebe

además sus propiedades: suficiencia, inseguridad, eficiencia, mínima varianza y consistencia.

Veamos cuál es la función de verosimilitud de los  $\text{J. a.}$

$$L_\beta(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f_\beta(x_i) = \prod_{i=1}^n x_i^4 \cdot \beta^{-5} \cdot e^{-\frac{x_i}{\beta}} \cdot \frac{1}{24}$$

$$L_\beta(x_1, x_2, \dots, x_n) = \frac{\beta^{-5n}}{(24)^n} \cdot e^{\frac{-\sum x_i}{\beta}} \cdot \prod_{i=1}^n x_i^4$$

$$\begin{aligned} Z &= \ln L_\beta(x_1, x_2, \dots, x_n) = -5n \ln \beta - n \ln 24 + \frac{1}{\beta} \sum_{i=1}^n x_i + \\ &+ \sum_{i=1}^n \ln x_i^4 \end{aligned}$$

$$\text{C.N. } \frac{\partial Z}{\partial \beta} = 0 \Rightarrow -\frac{5n}{\beta} + \frac{1}{\beta^2} \cdot \sum_{i=1}^n x_i = 0$$

$$-5n\beta + \sum_{i=1}^n x_i = 0 \Rightarrow \beta = \frac{\sum_{i=1}^n x_i}{5n}$$

$$\text{C.S. } \frac{\partial^2 Z}{\partial \beta^2} = \frac{5n}{\beta^2} - \frac{2}{\beta^3} \sum_{i=1}^n x_i$$

$$\frac{\partial^2 Z}{\partial \beta^2} \left( \frac{\sum x_i}{5n} \right) = \frac{\frac{5n}{(\sum x_i)^2}}{25n^2} - \frac{\frac{2}{(\sum x_i)^3}}{125n^3} \cancel{\sum x_i}$$

$$\frac{\partial^2 Z}{\partial \beta^2} \left( \frac{\sum x_i}{5n} \right) = \frac{125n^3}{(\sum x_i)^2} - \frac{250n^3}{(\sum x_i)^2} < 0 \text{ (máximo)}$$

$$\text{dijo } \hat{\beta}_{EMV} = \frac{\sum_{i=1}^n x_i}{5n}$$

•  $\hat{\beta}_{EMV}$  no es inseguro ya que:

$$E[\hat{\beta}_{EMV}] = \frac{1}{5n} \sum_{i=1}^n E[x_i]. \text{ Como } x_i \sim G(\beta, 5)$$

$$p=5 \quad R(p)=4!=24$$

$E[x_i] = \frac{5}{\beta}$ . Entonces:

$$E[\hat{\beta}_{EMV}] = \frac{1}{5n} \cdot \sum_{i=1}^n \frac{5}{\beta} = \frac{1}{5n} \cdot \frac{5n}{\beta} = \frac{1}{\beta} \neq \beta.$$

Por tanto  $\hat{\beta}_{EMV}$  no es insegado.

$f_\beta(x) = \frac{1}{24} x^4 \cdot \beta^{-5} \cdot e^{-\frac{1}{\beta}x}$  es de la familia exponencial ya que es de la forma:

$$f_\beta(x) = a(\beta) \cdot b(x) \cdot e^{c(\beta) \cdot d(x)}, \text{ en este caso:}$$

$a(\beta) = \beta^{-5}$ ,  $b(x) = \frac{1}{24} x^4$ ,  $c(\beta) = -\frac{1}{\beta}$ ,  $d(x) = x$ . Por tanto según el teorema de la familia exponencial  $T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n d(x_i) = \sum_{i=1}^n x_i$  es suficiente para  $\beta$ .

Como la función  $m(x) = \frac{x}{5n}$  es inyectiva:

$$m(x_1) = m(x_2) \Rightarrow \frac{x_1}{5n} = \frac{x_2}{5n} \Rightarrow x_1 = x_2, \text{ entonces:}$$

$$m\left(\sum_{i=1}^n x_i\right) = \frac{\sum_{i=1}^n x_i}{5n} \text{ es suficiente para } \beta$$

$\hat{\beta}_{EMV}$  no es eficiente ya que no es insegado. Veamos si es de mínima varianza:

$$\text{Cota FCR} = \frac{\left(\frac{\partial h(\beta)}{\partial \beta}\right)^2}{-n E\left(\frac{\partial^2 \ln L(\theta)}{\partial \theta^2}\right)}$$

$$h(\theta) = \theta \Rightarrow \frac{\partial h(\beta)}{\partial \beta} = 1.$$

$$\frac{\partial^2 \ln L(\beta)}{\partial \beta^2} = ? \quad L_\beta(x) = x^4 \cdot \beta^{-5} \cdot e^{-\frac{x}{\beta}} \cdot \frac{1}{24}$$

$$\ln L_\beta(x) = 4 \ln x - 5 \ln \beta - \ln 24 - \frac{1}{\beta} x.$$

$$\frac{\partial \ln L_\beta(x)}{\partial \beta} = -\frac{5}{\beta} + \frac{1}{\beta^2} x$$

$$\frac{\partial^2 \ln L_\beta(x)}{\partial \beta^2} = \frac{5}{\beta^2} - \frac{2}{\beta^3} x$$

$$E \left[ \frac{\partial^2 \ln L_\beta(x)}{\partial \beta^2} \right] = \frac{5}{\beta^2} - \frac{2}{\beta^3} \cdot E[x] = \frac{5}{\beta^2} - \frac{10}{\beta^4}$$

Luego

$$\text{Cota FCR} = \frac{1}{-n \left( \frac{5}{\beta^2} - \frac{10}{\beta^4} \right)} = \frac{1}{-n \cdot \frac{5\beta^2 - 10}{\beta^4}} = \frac{\beta^4}{n(10 - 5\beta^2)}$$

$$\text{Al ser } \hat{\beta}_{EMV} = \frac{\sum_{i=1}^n x_i}{5n} \Rightarrow \text{Var}[\hat{\beta}_{EMV}] = \text{Var}\left[\frac{\sum_{i=1}^n x_i}{5n}\right]$$

$$= \frac{1}{25n^2} \cdot \sum_{i=1}^n \text{Var}[x_i] = \frac{1}{25n^2} \cdot \left(\frac{5}{\beta^2}\right) \text{ Variancia de } G(\beta, 5) = \frac{1}{5(n\beta)^2}$$

Como  $\text{Var}[\hat{\beta}_{EMV}] \neq \text{Cota FCR}$  no podemos asegurar que este estimador sea de mínima varianza.

Por último veamos la consistencia de  $\hat{\beta}_{EMV}$ .

$$\text{El sesgo de } \hat{\beta}_{EMV} \text{ es } = E[\hat{\beta}_{EMV}] - \beta = \left(\frac{1}{\beta} - \beta\right)$$

$$\text{Lemos } ECM(\hat{\beta}_{EMV}) = \text{Var}[\hat{\beta}_{EMV}] + (\text{sesgo}(\hat{\beta}_{EMV}))^2$$

$$\Rightarrow ECM(\hat{\beta}_{EMV}) = \frac{1}{5n^2\beta^2} + \left(\frac{1}{\beta} - \beta\right)^2$$

$$\lim_{n \rightarrow \infty} ECM(\hat{\beta}_{EMV}) = \lim_{n \rightarrow \infty} \left( \frac{1}{5n^2\beta^2} + \left(\frac{1}{\beta} - \beta\right)^2 \right) =$$

$$= \left(\frac{1}{\beta} - \beta\right)^2 \Rightarrow \hat{\beta}_{EMV} \text{ no es consistente en medida cuadrática.}$$

18º Este ejercicio está resuelto en la teoría del tema 2

19º Sea  $X$  una v. a. con función de densidad  $f_\theta(x) = \frac{x \cdot e^{-\frac{x}{\theta}}}{\theta^2}$  si  $x > 0$  siendo  $\theta$  una constante real positiva desconocida. Sea  $x_1, x_2, \dots, x_n$  una m.a.s. de tamaño  $n$  extraída de la población.

a) Razone porqué' es esa familia de distribuciones exponencial. Demuestre la relación existente entre la familia exponencial y los estadísticos suficientes. Obtenga un estadístico suficiente para el parámetro  $\theta$  utilizando tanto la relación que ha demostrado como el criterio de factorización.

Esta distribución es exponencial ya que su función de densidad se puede expresar de la forma:

$$f_\theta(x) = a(\theta) \cdot b(x) \cdot e^{c(\theta)} \cdot d(x)$$

$$f_\theta(x) = \frac{1}{\theta^2} \cdot x \cdot e^{-\frac{1}{\theta} \cdot x}, \text{ en este caso:}$$

$$a(\theta) = \frac{1}{\theta^2}; \quad b(x) = d(x) = x; \quad c(\theta) = -\frac{1}{\theta}$$

El criterio de factorización dice que:

$$\text{Es suficiente} \Leftrightarrow f_\theta(x_1, x_2, \dots, x_n) = h(x_1, x_2, \dots, x_n) \cdot g_\theta(T(x_1, x_2, \dots, x_n))$$

donde  $h$  es una función que tan solo depende de la muestra  $\{x_1, x_2, \dots, x_n\}$  y  $g_\theta$  depende del parámetro  $\theta$  y del valor que toma el estadístico  $T$  en esa muestra.

Si una distribución pertenece a la familia exponencial su función de densidad (o de probabilidad que lo mismo da) es de la forma

$$f_\theta(x) = a(\theta) \cdot b(x) \cdot e^{c(\theta)} \cdot d(x). \text{ Por tanto la función}$$

de densidad conjunta es:

$$f_{\theta}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f_{\theta}(x_i) = \prod_{i=1}^n a(\theta) \cdot b(x_i) \cdot e^{c(\theta)} \cdot d(x_i)$$

es decir que  $f_{\theta}(x_1, x_2, \dots, x_n)$  se puede expresar como:

$$f_{\theta}(x_1, x_2, \dots, x_n) = [a(\theta)]^n \cdot \left( \prod_{i=1}^n b(x_i) \right) \cdot e^{c(\theta)} \cdot \sum_{i=1}^n d(x_i)$$

Si  $T(x_1, x_2, \dots, x_n) = \sum d(x_i)$   $T$  sería suficiente

para  $\theta$  ya que por el criterio de factorización  $f_{\theta}(x_1, x_2, \dots, x_n)$  se podría expresar como el pro-

ducto de una función que tan sólo depende de la muestra  $h(x_1, x_2, \dots, x_n) = \prod_{i=1}^n b(x_i)$  por otra función

$$g_{\theta} = [a(\theta)]^n \cdot e^{c(\theta)} \cdot T(x_1, x_2, \dots, x_n)$$

que tan sólo depen-  
de de  $\theta$  y del valor que toma  $T$  en la muestra.

En nuestro caso, al ser  $d(x) = x$  el estimador suficiente para  $\theta$  sería:

$$T(x_1, x_2, \dots, x_n) = \sum_{i=1}^n d(x_i) = \sum_{i=1}^n x_i .$$

b) Obenga el estimador máximo-verosimil de  $\theta$  y el de  $\frac{1}{\theta}$  y conteste a las siguientes preguntas

demostrando siempre su respuesta:

b1) ¿ Son dichos estimadores suficientes ?

b2) ¿ Insegados ? ¿ Consistentes ?

b3) ¿ Insegados de mínima varianza uniforme ?

Halle la correspondiente cba de FCR.

\* Estimador de máxima verosimilitud de  $\theta$

la función de verosimilitud de  $\theta$  es:

$$L_{\theta}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \frac{x_i \cdot e^{-\frac{x_i}{\theta}}}{\theta^2} = \frac{1}{\theta^{2n}} \cdot \left( \prod_{i=1}^n x_i \right) \cdot e^{-\frac{1}{\theta} \sum_{i=1}^n x_i}$$

$$\ln L_{\theta}(x_1, x_2, \dots, x_n) = \ln \left( \prod_{i=1}^n x_i \right) - 2n \ln \theta - \frac{1}{\theta} \sum_{i=1}^n x_i$$

si derivamos respecto a  $\theta$ :

$$\frac{\partial \ln L_\theta(x_1, x_2, \dots, x_n)}{\partial \theta} = -2n \cdot \frac{1}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i = 0$$

$$-2n\theta + \sum_{i=1}^n x_i = 0 \Rightarrow \hat{\theta} = \frac{\sum_{i=1}^n x_i}{2n}$$

$$\frac{\partial^2 \ln L_\theta(x_1, x_2, \dots, x_n)}{\partial \theta^2} = \frac{-2n}{\theta^2} - \frac{2}{\theta^3} \cdot \sum_{i=1}^n x_i$$

$$\frac{\partial^2 \ln L_\theta(x_1, x_2, \dots, x_n)}{\partial \theta^2} \left( \frac{\sum_{i=1}^n x_i}{2n} \right) = \frac{8n^3}{(\sum_{i=1}^n x_i)^2} - \frac{16n^3}{(\sum_{i=1}^n x_i)^2} < 0$$

Entonces  $\hat{\theta}_{EMV} = \frac{\sum_{i=1}^n x_i}{2n}$

da función de verosimilitud podríamos escribir la en términos de  $\beta = \frac{1}{\theta}$  como:

$f_\beta(x) = \beta^2 \cdot x \cdot e^{-\beta x}$ . En este caso la función de verosimilitud es:

$$L_\beta(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \beta^2 \cdot x_i \cdot e^{-\beta x_i} = \left( \prod_{i=1}^n x_i \right) \cdot \beta^{2n} \cdot e^{-\beta \sum_{i=1}^n x_i}$$

Tomemos  $\ln$ :

$$z = \ln L_\beta(x_1, x_2, \dots, x_n) = \sum_{i=1}^n \ln(x_i) + 2n \ln \beta - \beta \sum_{i=1}^n x_i$$

$$\frac{\partial z}{\partial \beta} = \frac{2n}{\beta} - \sum_{i=1}^n x_i = 0 \Rightarrow \beta = \frac{2n}{\sum_{i=1}^n x_i}$$

$$\frac{\partial^2 z}{\partial \beta^2} = -\frac{2n}{\beta^2} < 0 \text{ máximo. Entonces}$$

$$\beta_{EMV} = \left( \frac{1}{\theta} \right)_{EMV} = \frac{2n}{\sum_{i=1}^n x_i}$$

Veamos si  $\theta_{EMV} = \frac{\sum_{i=1}^n x_i}{2n}$  es insegundo, para ello

necesitaremos calcular  $E[x]$ .

$$E[x] = \int_{-\infty}^{+\infty} x \cdot f_\theta(x) dx = \int_0^{+\infty} x \cdot x \cdot e^{-\frac{1}{\theta}x} \cdot \frac{1}{\theta^2} dx$$

$$= \frac{1}{\theta^2} \cdot \int_0^{+\infty} x^2 \cdot e^{-\frac{1}{\theta}x} dx.$$

Calcularemos la integral  $\int x^2 \cdot e^{-\frac{1}{\theta}x} dx$  aplicando dos veces el método de integración por partes

$$\int x^2 \cdot e^{-\frac{1}{\theta}x} dx \quad \left\{ \begin{array}{l} u = x^2 \Rightarrow du = 2x dx \\ dv = e^{-\frac{1}{\theta}x} dx \Rightarrow v = -\theta \cdot e^{-\frac{1}{\theta}x} \end{array} \right\} =$$

$$= -\theta x^2 e^{-\frac{1}{\theta}x} + 2\theta \cdot \int x \cdot e^{-\frac{1}{\theta}x} dx \quad \left\{ \begin{array}{l} u = x \Rightarrow du = dx \\ dv = e^{-\frac{1}{\theta}x} dx \Rightarrow v = -\theta e^{-\frac{1}{\theta}x} \end{array} \right\} =$$

$$= -\theta x^2 e^{-\frac{1}{\theta}x} + 2\theta \left( -\theta x e^{-\frac{1}{\theta}x} + \theta \int e^{-\frac{1}{\theta}x} dx \right) =$$

$$= -\theta x^2 e^{-\frac{1}{\theta}x} - 2\theta^2 x e^{-\frac{1}{\theta}x} - 2\theta^3 \cdot e^{-\frac{1}{\theta}x} = -\theta e^{-\frac{1}{\theta}x} (x^2 - 2\theta x - 2\theta^2)$$

Por tanto:

$$\int_0^{+\infty} x^2 \cdot e^{-\frac{1}{\theta}x} dx = \left[ -\theta e^{-\frac{1}{\theta}x} (x^2 - 2\theta x - 2\theta^2) \right]_0^{+\infty} = 2\theta^4$$

$$\text{Entonces } E[x] = \frac{1}{\theta^2} \cdot 2\theta^4 = 2\theta^2.$$

Veamos que  $\theta_{EMV}$  es insegundo

$$E[\theta_{EMV}] = E\left[\frac{\sum_{i=1}^n x_i}{2n}\right] = \frac{1}{2n} \cdot \sum_{i=1}^n E[x_i] = \frac{1}{2n} \cdot \sum_{i=1}^n 2\theta$$

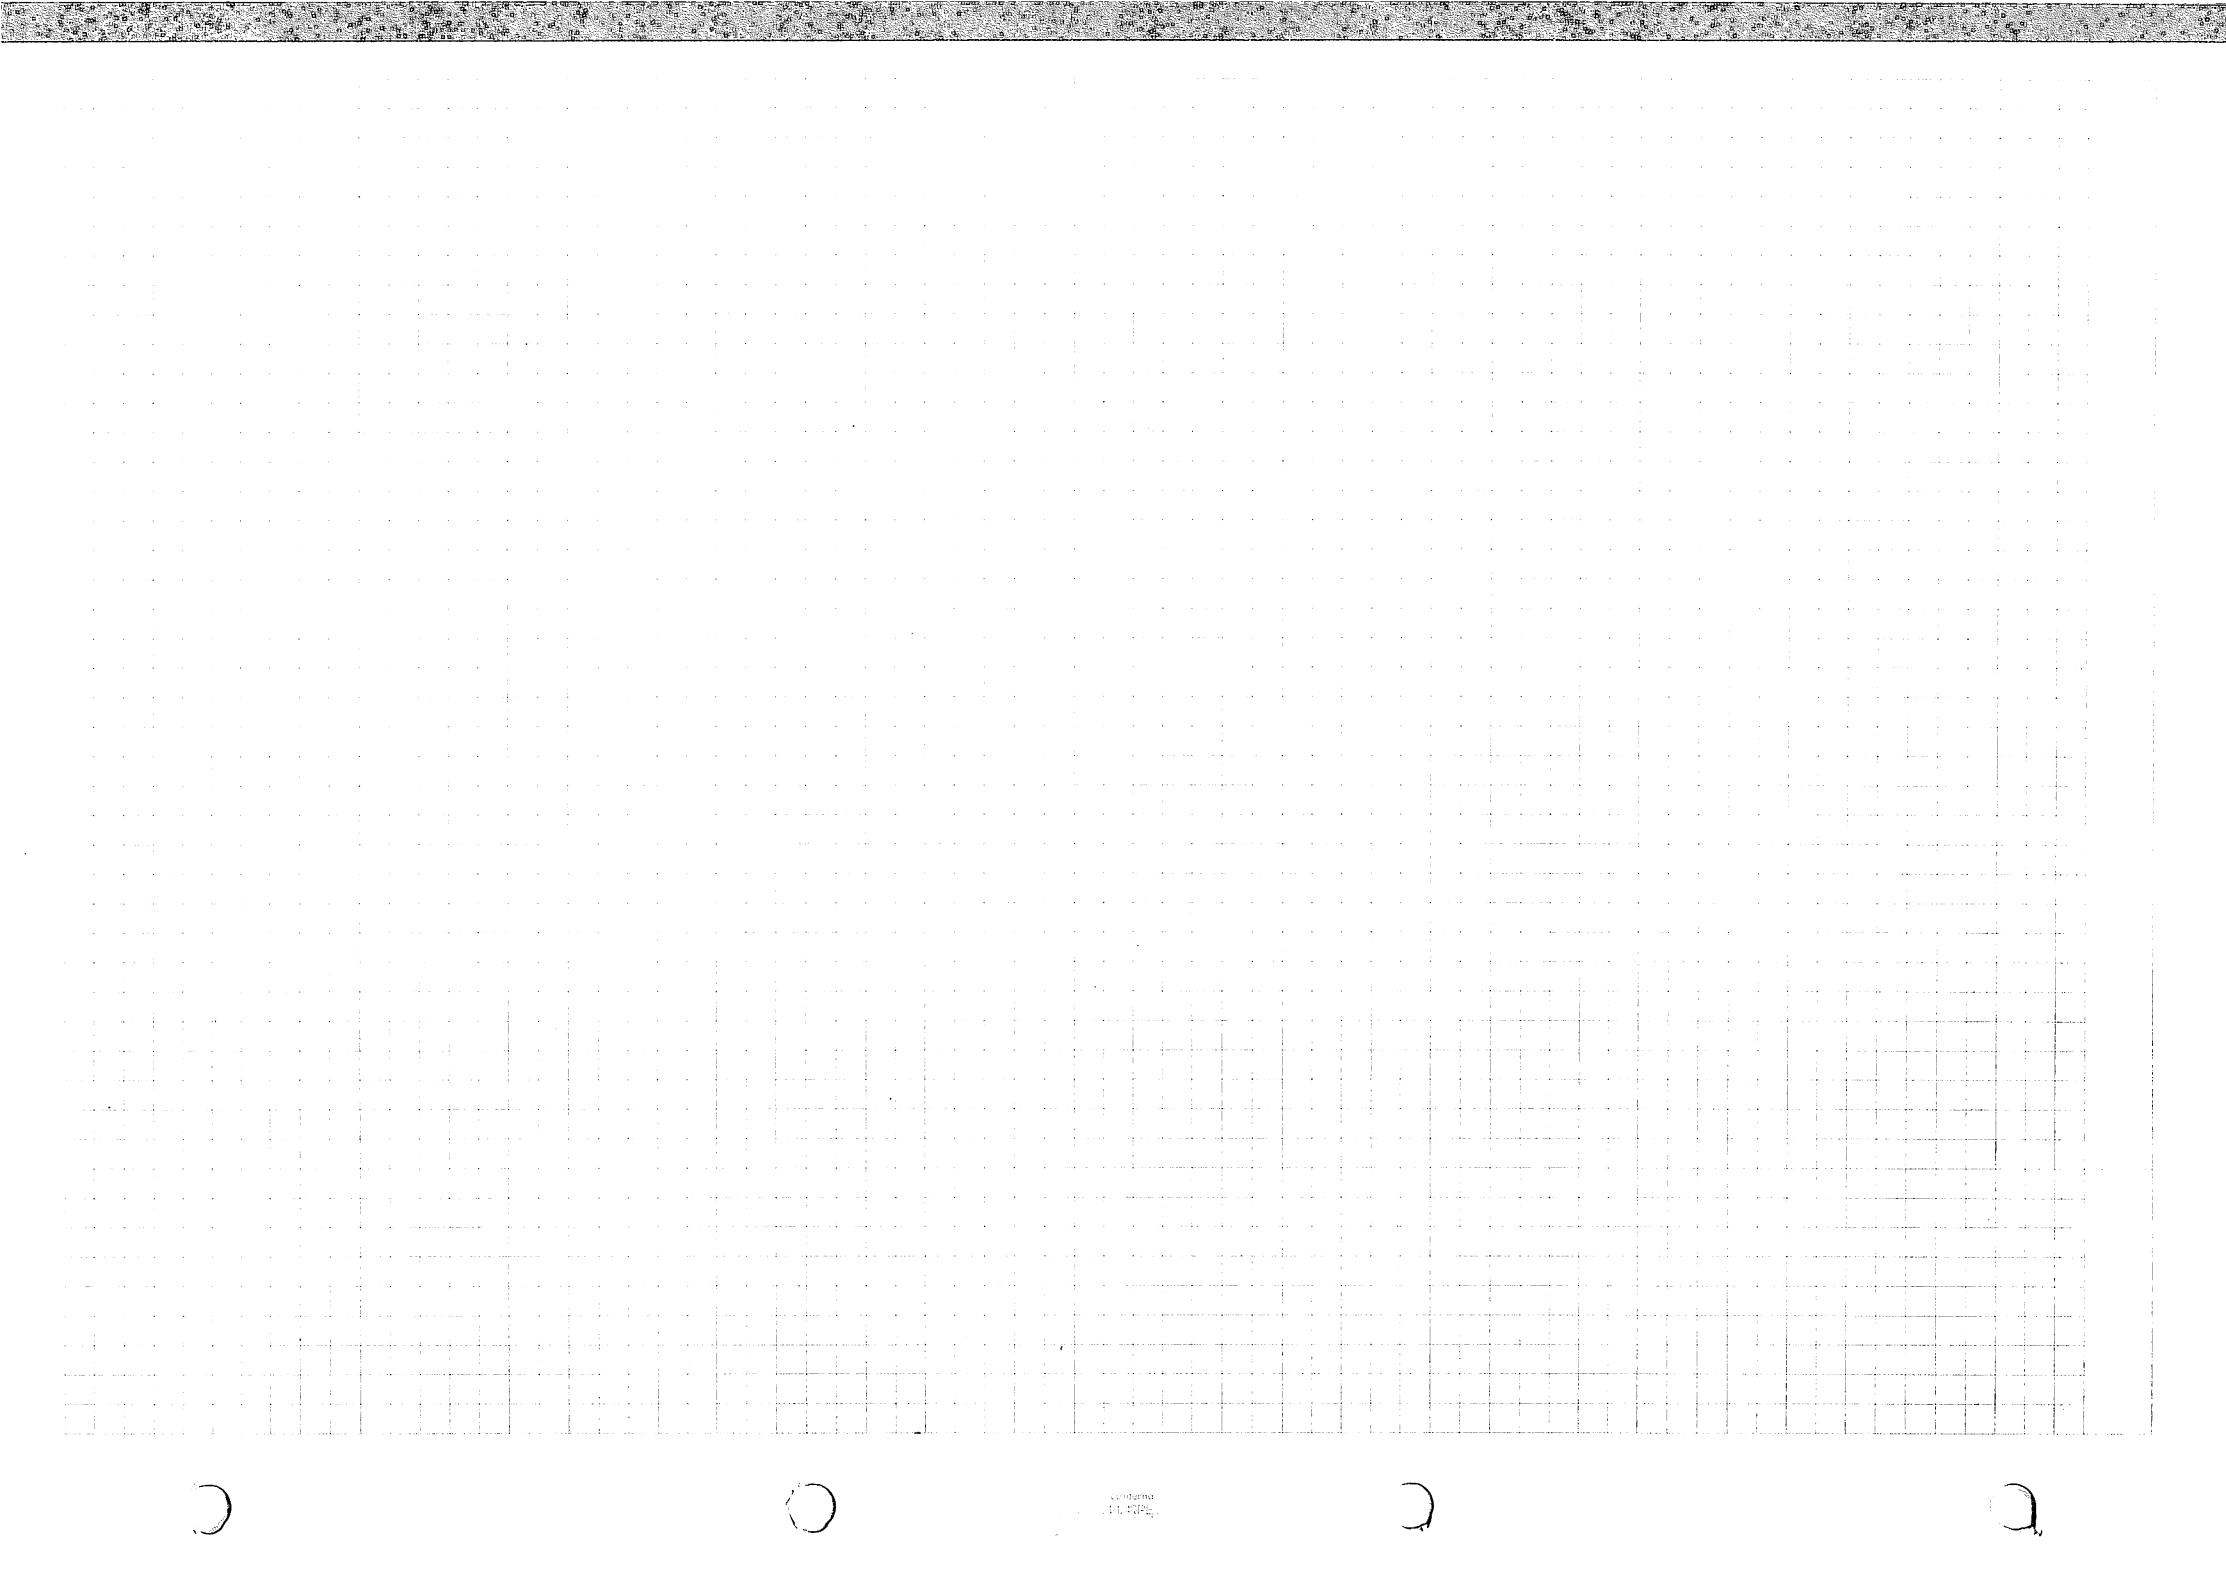
$$E[\theta_{EMV}] = \frac{1}{2n} \cdot 2n\theta = \theta$$

$$\text{Como } \left(\frac{1}{\theta}\right)_{EMV} = \frac{2n}{\sum_{i=1}^n x_i} \text{ para ver si es insegundo}$$

necesitaremos ver cuál es la función de densidad de la variable  $T = \frac{1}{\sum_{i=1}^n x_i}$

• Función de distribución de  $T$

$$F_T(t) = P[T \leq t] = p$$



Centro  
de la Caja