

estimación puntual

Carlos Carleos, Norberto Corral

21 de noviembre de 2022

Índice

1. generalidades	1
1.1. definiciones	1
1.2. propiedades deseables de un estimador	2
2. método de los momentos	2
2.1. propiedades	2
2.2. descripción	2
2.3. ejemplo	2
2.4. método delta	2
2.4.1. nombre	2
2.4.2. teorema	3
2.4.3. ejemplo	4
3. método de máxima verosimilitud	4
3.1. intro	4
3.1.1. ejemplo	4
3.1.2. definiciones	5
3.1.3. ejemplo (exponencial)	5
3.1.4. ejemplo (bernuli)	6
3.1.5. ejemplo con verosimilitud no derivable	6
3.1.6. ejemplo EMV no único	6
3.1.7. ejemplo sin solución explícita	6
3.1.8. ejemplo gaussiano	7
3.1.9. ejemplos triangular	7
3.2. propiedades	8
3.2.1. EMV función del suficiente	8
3.2.2. equivarianza o invariancia funcional	8
3.2.3. comportamiento asintótico	8

1. generalidades

1.1. definiciones

estimador estadígrafo $T = \hat{\theta}$ que toma valores en el espacio paramétrico Θ

estimación valor $t = T(\vec{x}) = \hat{\theta}(\vec{x}) = \hat{\theta}$ que toma el estimador dada una muestra concreta \vec{x}

1.2. propiedades deseables de un estimador

insesgadez $E(T) = E(\hat{\theta}) = \theta$

eficiencia mínima varianza (cota de Fréchet, Cramér y Rao)

ECM error cuadrático medio, $ECM(T) = E[(T - \theta)^2] = E[(T - E[T])^2] + [E(T) - \theta]^2 = \text{Var}(T) + [\text{sesgo}(T)]^2$

consistencia $T_n \xrightarrow[n \rightarrow \infty]{P} \theta$

2. método de los momentos

2.1. propiedades

- el más antiguo
- sencillo
- versátil
- puede dar valores fuera de Θ

2.2. descripción

- la distribución de X depende de $\vec{\theta} = (\theta_1, \dots, \theta_k)$
- sean $\alpha_1, \dots, \alpha_r$ momentos finitos de la población X

$$\forall i = 1, \dots, r, \quad \exists g_i, \quad \alpha_i = g_i(\vec{\theta})$$

- sean a_1, \dots, a_n momentos muestrales de \vec{x} extraída de X
- hállese las h despejando las ecuaciones

$$\left. \begin{array}{l} a_1 \approx \alpha_1 = g_1(\vec{\theta}) \\ \vdots \\ a_r \approx \alpha_r = g_r(\vec{\theta}) \end{array} \right\} \implies \hat{\theta}_i = h_i(a_1, \dots, a_r)$$

2.3. ejemplo

- $X \hookrightarrow N(\mu, \sigma) \implies \mu = \alpha_1, \sigma^2 = \alpha_2 - \alpha_1^2 \implies \hat{\mu} = \bar{x}, \hat{\sigma}^2 = s^2$
- $X \hookrightarrow U(0, \theta) \implies \alpha_1 = \frac{\theta}{2} \implies \hat{\theta} = 2\bar{x}$ que no es función del estadígrafo suficiente $X_{(n)}$
- $X \hookrightarrow U(-\theta, \theta) \implies \alpha_1 = 0, \alpha^2 = \text{Var}(X) = \frac{\theta^2}{3} \implies \hat{\theta} = \sqrt{3\bar{x}^2}$ que no es función del estadígrafo suficiente $(X_{(1)}, X_{(n)})$

2.4. método delta

2.4.1. nombre

deriva del «método δ » de Dorfman 1938

2.4.2. teorema

1. enunciado

- sea $(T_n)_{n \in \mathbb{N}}$ sucesión de estadígrafos muestreados a partir de $X \hookrightarrow F_\theta$ y tales que

$$\frac{T_n - \theta}{\frac{\sigma}{\sqrt{n}}} \xrightarrow[n \rightarrow \infty]{L} N(0, 1) \quad \text{es decir} \quad T_n \overset{\sim}{\hookrightarrow} N\left(\theta, \frac{\sigma}{\sqrt{n}}\right)$$

- sea g derivable con $g'(\theta) \neq 0 \forall \theta \in \Theta$
- entonces

$$\frac{g(T_n) - g(\theta)}{\frac{\sigma}{\sqrt{n}}|g'(\theta)|} \xrightarrow[n \rightarrow \infty]{L} N(0, 1) \quad \text{es decir} \quad g(T_n) \overset{\sim}{\hookrightarrow} N\left(g(\theta), \frac{\sigma}{\sqrt{n}}|g'(\theta)|\right)$$

2. demostración

- se sabe que $X_n \xrightarrow{L} X \implies cX_n \xrightarrow{L} cX$
- por tanto, $\frac{T_n - \theta}{\frac{\sigma}{\sqrt{n}}} \xrightarrow[n \rightarrow \infty]{L} N(0, 1) \implies (T_n - \theta)\sqrt{n} \xrightarrow[n \rightarrow \infty]{L} N(0, \sigma) \implies (T_n - \theta)\sqrt{n}|g'(\theta)| \xrightarrow[n \rightarrow \infty]{L} N(0, \sigma|g'(\theta)|)$
- $[g(T_n) - g(\theta)]\sqrt{n} = \frac{g(T_n) - g(\theta)}{T_n - \theta}(T_n - \theta)\sqrt{n}$
- se sabe que

$$\left. \begin{array}{l} X_n \xrightarrow{L} X \\ Y_n \xrightarrow{P} c \end{array} \right\} \implies X_n Y_n \xrightarrow{L} cX$$

- basta probar $Y_n = \frac{g(T_n) - g(\theta)}{T_n - \theta} \xrightarrow{P} g'(\theta)$
- por definición de derivada

$$\forall \epsilon > 0, \quad \exists \delta_\epsilon > 0, \quad |T_n - \theta| < \delta_\epsilon \implies \left| \frac{g(T_n) - g(\theta)}{T_n - \theta} - g'(\theta) \right| < \epsilon$$

luego

$$\{\omega \in \Omega : |T_n(\omega) - \theta| < \delta_\epsilon\} \subset \left\{ \omega \in \Omega : \left| \frac{g(T_n) - g(\theta)}{T_n - \theta} - g'(\theta) \right| < \epsilon \right\}$$

luego

$$\begin{aligned} \lim_{n \rightarrow \infty} \Pr \left[\left| \frac{g(T_n) - g(\theta)}{T_n - \theta} - g'(\theta) \right| < \epsilon \right] &\geq \lim \Pr[|T_n - \theta| < \delta_\epsilon] \\ &= \lim \Pr \left[\frac{\sqrt{n}|T_n - \theta|}{\sigma} < \frac{\sqrt{n}\delta_\epsilon}{\sigma} \right] \\ &\geq \lim \Pr \left[\frac{\sqrt{n}|T_n - \theta|}{\sigma} < \frac{\sqrt{n_0}\delta_\epsilon}{\sigma} \right] \\ &= \Pr \left[|N(0, 1)| < \frac{\sqrt{n_0}\delta_\epsilon}{\sigma} \right] \\ &> 1 - \epsilon \end{aligned}$$

tomando n_0 suficientemente grande

- por tanto

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow \infty} \Pr \left[\left| \frac{g(T_n) - g(\theta)}{T_n - \theta} - g'(\theta) \right| < \epsilon \right] > 1 - \epsilon$$

luego

$$\lim_{n \rightarrow \infty} \Pr \left[\left| \frac{g(T_n) - g(\theta)}{T_n - \theta} - g'(\theta) \right| < \epsilon \right] = 1$$

o sea

$$\frac{g(T_n) - g(\theta)}{T_n - \theta} \xrightarrow{P} g'(\theta)$$

2.4.3. ejemplo

- $X \leftrightarrow \text{Exp}(\lambda)$
- $E(X) = \frac{1}{\lambda} \implies \hat{\lambda}_{\text{MM}} = \frac{1}{\bar{X}}$
- por TCL, $T = \bar{X} \xrightarrow{\sim} N\left(\theta, \frac{\sigma}{\sqrt{n}}\right)$ con $\theta = \frac{1}{\lambda}$ y $\sigma = \frac{1}{\lambda}$
- sea $g(x) = \frac{1}{x}$ con $g'(x) = -\frac{1}{x^2}$
- entonces $\hat{\lambda}_{\text{MM}} = g(T) \xrightarrow{\sim} N\left(g(\theta), \frac{\sigma}{\sqrt{n}}|g'(\theta)|\right) = N\left(g\left(\frac{1}{\lambda}\right), \frac{\sigma}{\sqrt{n}}\left|g'\left(\frac{1}{\lambda}\right)\right|\right) = N\left(\lambda, \frac{1/\lambda}{\sqrt{n}} \left| -\frac{1}{\left(\frac{1}{\lambda}\right)^2} \right| \right) = N\left(\lambda, \frac{1/\lambda}{\sqrt{n}} \lambda^2\right) = N\left(\lambda, \frac{\lambda}{\sqrt{n}}\right)$

```
## X = Exp(landa)
landa <- 2 # parAmetro
n <- 100 # tamaNo muestral
m <- 1e6 # tamaNo montecarlo
zita <- 1/landa # E(X)
sigma <- 1/landa # DT(X)
T <- mean # estadIgrafo T=N(zita,sigma/n)
g <- function (x) 1/x # estimador g(T) = N (landa, landa/raIz(n))
gprima <- function (x) -1/x^2 # g(T) = N (g(zita), sigma/n*abs(gprima(zita)))
gprima <- function (t) eval (D(expression(1/x),"x"), list(x=t)) # otra forma
d <- replicate (m, g(T(rexp(n,landa)))) # distribuciOn de g(T)
c (landa, mean(d)) # esperanza y media de montacarlo
c (landa/sqrt(n), sigma/n*abs(gprima(zita)), sd(d)) # desvIos tIpicos
plot (ecdf (d)) # ojiva empIrica
plot (function (x) pnorm (x, landa, landa/sqrt(n)), # ojiva asintOtica
      min(d), max(d), col=2, add=TRUE) # por mEtodo delta
dev.new () # nueva ventana grAfica
plot (density (d)) # densidad estimada mediante "nUcleos"
plot (function (x) dnorm (x, landa, landa/sqrt(n)), # densidad asintOtica
      min(d), max(d), col=2, add=TRUE) # por mEtodo delta
```

3. método de máxima verosimilitud

3.1. intro

3.1.1. ejemplo

- dos máquinas, A y B, fabrican tornillos
- la máquina A produce un 1% de tornillos defectuosos
- la máquina B produce un 8% de tornillos defectuosos
- una caja contiene diez tornillos, dos de ellos defectuosos, fabricados todos por la misma máquinas
- ¿qué máquina los fabricó?
- sea $X|i = \text{"número de tornillos defectuosos entre diez tornillos fabricados en la máquina } i\text{"}$
- entonces $X|A \leftrightarrow B(10, \frac{1}{100})$ y $X|B \leftrightarrow B(10, \frac{8}{100})$
- $\Pr(X = 2 | A) = \text{dbinom}(2, 10, .01) = 0,004152351 \ll 0,147807 = \text{dbinom}(2, 10, .08) = \Pr(X = 2 | B)$

- la muestra de la caja es mucho más verosímil si viene de B que si viene de A
- OJO: no estamos calculando $\Pr(A | X = 2)$ ni $\Pr(B | X = 2)$; para eso necesitaríamos $\Pr A$ y $\Pr B$ y aplicar la fórmula de Bayes

3.1.2. definiciones

verosimilitud función de verosimilitud (*likelihood* en inglés) asociada a la muestra \vec{x} de la población $X \leftrightarrow F_\theta$

$$L(\vec{x}, \theta) = L_{\vec{x}}(\theta) = f(\vec{x}, \theta)$$

es función de θ , pues \vec{x} es fija

EMV estimador máximo-verosímil de θ

$$\hat{\theta}_{\text{MV}} = \arg \sup_{\theta \in \Theta} L(\vec{x}, \theta)$$

luego

$$L(\vec{x}, \hat{\theta}_{\text{MV}}) \geq L(\vec{x}, \theta) \quad \forall \theta \in \Theta$$

logverosimilitud logaritmo de la verosimilitud, $\log L$ o $\ln L$; a menudo es más sencillo y robusto maximizar la logverosimilitud $\ln L$ que directamente L

informante si la logverosimilitud es derivable, se define el informante (*score*)

$$u(\theta) = \frac{\partial}{\partial \theta} \ln L(\vec{x}, \theta)$$

ecuación de verosimilitud a menudo el EMV está entre las soluciones de

$$u(\theta) = 0$$

puede haber varios EMV

3.1.3. ejemplo (exponencial)

- $X =$ tiempo de "vida" de cierto tipo de aparato
- $X \leftrightarrow \text{Exp}(\theta)$

1. información completa

- calcula el EMV de θ si se dispone de la duración de n aparatos, es decir, una muestra \vec{x} de X

$$f(x, \theta) = \theta e^{-\theta x} \implies L(\vec{x}, \theta) = \theta^n e^{-\theta \sum x_i} \implies \ln L(\vec{x}, \theta) = n \ln \theta - \theta \sum x_i \implies 0 = u(\theta) = \frac{\partial}{\partial \theta} \ln L(\vec{x}, \theta) = \frac{n}{\theta} - \sum x_i \implies \frac{n}{\theta} = \sum x_i \implies \hat{\theta}_{\text{MV}} = \frac{n}{\sum x_i} = \frac{1}{\bar{x}}$$

2. información censurada

- calcula el EMV de θ si se dispone de la duración de $n - r$ aparatos; de los otros r se sabe sólo que han durado un tiempo mayor que t_0 (por ejemplo, por un límite en la duración del experimento)

$$f(x, \theta) = \theta e^{-\theta x}, \Pr(X > t_0) = 1 - F(t_0) = e^{-\theta t_0} \implies L(\vec{x}, \theta) = e^{-r\theta t_0} \times \theta^{n-r} e^{-\theta \sum_{i=1}^{n-r} x_{(i)}} = \theta^{n-r} e^{-\theta(\sum_{i=1}^{n-r} x_{(i)} + r t_0)} \implies \ln L(\vec{x}, \theta) = (n-r) \ln \theta - \theta(\sum_{i=1}^{n-r} x_{(i)} + r t_0) \implies 0 = \frac{n-r}{\theta} - (\sum_{i=1}^{n-r} x_{(i)} + r t_0) \implies \frac{n-r}{\theta} = \sum_{i=1}^{n-r} x_{(i)} + r t_0 \implies \hat{\theta}_{\text{MV}} = \frac{n-r}{\sum_{i=1}^{n-r} x_{(i)} + r t_0}$$

3.1.4. ejemplo (bernuli)

$X \hookrightarrow B(1, p) \implies L(\vec{x}, p) = p^{\sum x_i} (1-p)^{n-\sum x_i} \implies \ln L(\vec{x}, p) = \sum x_i \log p + (n - \sum x_i) \ln(1-p) \implies$
 $0 = \frac{\partial}{\partial p} \ln L(\vec{x}, p) = \frac{\sum x_i}{p} + \frac{n-\sum x_i}{1-p} \implies \frac{\sum x_i}{p} = \frac{n-\sum x_i}{1-p} \implies (1-p) \sum x_i = p(n - \sum x_i) \implies \hat{p}_{MV} = \frac{\sum x_i}{n} = \bar{x}$
 es decir, la proporción de unos

3.1.5. ejemplo con verosimilitud no derivable

$X \hookrightarrow U(0, \theta) \implies L(\vec{x}, \theta) = \frac{1}{\theta^n} I(x_{(n)} < \theta) = \begin{cases} 0 & \theta < x_{(n)} \\ \frac{1}{\theta^n} & \theta > x_{(n)} \end{cases}$ (no derivable) \implies el supremo se alcanza en
 $\theta = x_{(n)} \implies \hat{\theta}_{MV} = x_{(n)}$

3.1.6. ejemplo EMV no único

$X \hookrightarrow U(\theta, \theta + 3) \implies f(\vec{x}, \theta) = \frac{1}{3} I(\theta < x < \theta + 3) \implies L(\vec{x}, \theta) = \frac{1}{3^n} I(x_{(n)} - 3 < \theta < x_{(1)}) \implies$ cualquier valor entre $X_{(n)} - 3$ y $X_{(1)}$ es EMV, por ejemplo $T = \frac{X_{(n)} - 3 + X_{(1)}}{2}$

3.1.7. ejemplo sin solución explícita

$Y \hookrightarrow P(\lambda), X = \begin{cases} 1 & Y \leq 1 \\ 2 & Y = 2, n_i = \sum_{j=1}^n I(X_j = i) \forall i = 1, 2, 3 \\ 3 & Y \geq 3 \end{cases}$
 $\implies L(\vec{x}, \lambda) = (e^{-\lambda}[1 + \lambda])^{n_1} \left(e^{-\lambda} \frac{\lambda^2}{2}\right)^{n_2} \left(1 - e^{-\lambda} \left[1 + \lambda + \frac{\lambda^2}{2}\right]\right)^{n_3}$

No se puede encontrar una solución explícita de la ecuación de verosimilitud:

```
(%i17) L(n1,n2,n3,landa) :=
      (exp(-landa)*(1+landa))~n1 *
      (exp(-landa)*landa^2/2)~n2 *
      (1-exp(-landa)*(1+landa+landa^2/2))~n3 $

(%i18) tex (diff (L(n1,n2,n3,landa), landa)) $

      (\lambda+1)^{n_1} \frac{\left(1 - \left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda}\right)^{n_3 - 1} \left(\left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda} - (\lambda + 1) e^{-\lambda}\right) |\lambda|^{2n_2} e^{-\lambda n_2 - \lambda n_1} n_3}{2^{n_2}}
      +
      \frac{(\lambda+1)^{n_1} \left(1 - \left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda}\right)^{n_3} |\lambda|^{2n_2} (-n_2 - n_1) e^{-\lambda n_2 - \lambda n_1}}{2^{n_2}}
      +
      \frac{(\lambda+1)^{n_1 - 1} \left(1 - \left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda}\right)^{n_3} |\lambda|^{2n_2} n_1 e^{-\lambda n_2 - \lambda n_1}}{2^{n_2}}
      +
      \frac{(\lambda+1)^{n_1} \left(1 - \left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda}\right)^{n_3} |\lambda|^{2n_2} n_2 2^{1-n_2} e^{-\lambda n_2 - \lambda n_1}}{\lambda}
```

```
(%i23) logexpand:all $
```

```
(%i24) define (lnL(landa), log(L(n1,n2,n3,landa))) $
```

```
(%i25) define (u(landa), diff(lnL(landa),landa)) $ /* informante */
```

```
(%i26) freeof (landa, rhs (solve (u(landa), landa) [1])) ; /* no puede despejar landa */
```

```
(%o26) false
```

```
(%i27) tex (u(landa)) $
```

$$u(\lambda) = \frac{\left(\left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda} - (\lambda + 1) e^{-\lambda}\right) n_3}{1 - \left(\frac{\lambda^2}{2} + \lambda + 1\right) e^{-\lambda}} + \frac{2n_2}{\lambda} - n_2 + \frac{n_1}{\lambda + 1} - n_1$$

Hay que recurrir a métodos numéricos:

```
> L <- function(n1,n2,n3,landa) (exp(-landa)*(1+landa))~n1 *
                                (exp(-landa)*landa^2/2)^n2 *
                                (1-exp(-landa)*(1+landa+landa^2/2))^n3
> optimize (function (landa) L(3,3,4,landa), c(0,10), maximum=TRUE)
$maximum
[1] 2.342104

$objective
[1] 1.803925e-05
```

En este caso, la maximización directa de la verosimilitud no da problemas. Sin embargo, por robustez numérica (para que el producto de probabilidades no dé un cero numérico y la función quede plana) a menudo es recomendable maximizar la logverosimilitud:

```
> optimize (function (landa) log(L(3,3,4,landa)), c(0,10), maximum=TRUE)
$maximum
[1] 2.342112

$objective
[1] -10.92296
```

3.1.8. ejemplo gaussiano

$$X \hookrightarrow N(\mu, \sigma) \implies L(\vec{x}, \mu, \sigma) = \frac{1}{\sigma^n \sqrt{2\pi}^n} e^{-\frac{1}{2\sigma^2} \sum (x_i - \mu)^2} \implies \ln L(\vec{x}, \mu, \sigma) = -n \ln \sigma - n \ln \sqrt{2\pi} - \frac{1}{2\sigma^2} \sum (x_i - \mu)^2$$

$$0 = \frac{\ln L(\vec{x}, \mu, \sigma)}{\partial \mu} = -\frac{1}{2\sigma^2} \sum (x_i - \mu) 2(-1) \implies \sum x_i = n\mu$$

$$0 = \frac{\ln L(\vec{x}, \mu, \sigma)}{\partial \sigma} = \frac{-n}{\sigma} - \frac{1}{2\sigma^{-3}} (-2) \sum (x_i - \mu)^2 \implies \sigma^2 n = \sum (x_i - \mu)^2$$

$$\implies \hat{\mu}_{MV} = \frac{\sum x_i}{n} = \bar{x}, \hat{\sigma}_{MV}^2 = \frac{\sum (x_i - \bar{x})^2}{n} = s^2$$

3.1.9. ejemplos triangular

1. beta escalada, densa cabe θ

$$\blacksquare X \hookrightarrow \theta \cdot \beta(2, 1) \implies f = \frac{2x}{\theta^2} I(x < \theta) \implies L = \frac{2^n \prod x_i}{\theta^{2n}} I(x_{(n)} < \theta) \implies \forall \theta > x_{(n)}, \ln L = n \ln 2 + \sum \ln x_i - 2n \ln \theta \implies \frac{\partial \ln L}{\partial \theta} = -\frac{2n}{\theta} < 0 \implies L \text{ es decreciente}$$

$$\blacksquare \text{EMV } \hat{\theta} = X_{(n)}$$

2. beta escalada, densa cabe 0

$$\blacksquare X \hookrightarrow \theta \cdot \beta(1, 2) \implies f = \frac{2(1-\frac{x}{\theta})}{\theta} I(x < \theta) \implies L = \frac{2^n \prod (1-\frac{x_i}{\theta})}{\theta^n} I(x_{(n)} < \theta) \implies \forall \theta > x_{(n)}, \ln L = n \ln 2 + \sum \ln \left(1 - \frac{x_i}{\theta}\right) - n \ln \theta \implies \frac{\partial \ln L}{\partial \theta} = \sum \frac{-\frac{x_i}{\theta^2}}{1-\frac{x_i}{\theta}} - \frac{n}{\theta} = \sum \frac{x_i}{\theta x_i - \theta^2} - \frac{n}{\theta} = \implies \left\{ \begin{array}{l} 0 = \frac{\partial \ln L}{\partial \theta} \implies \\ \sum \frac{x_i}{x_i - \theta} = n \end{array} \right.$$

$$\blacksquare \text{EMV debe obtenerse numéricamente}$$

3.2. propiedades

3.2.1. EMV función del suficiente

- sea T estadígrafo suficiente
- sea $\hat{\theta}$ el único EMV
- entonces $\hat{\theta}$ es función de T
- demostración: T suficiente $\implies L(\vec{x}, \theta) = g(T[\vec{x}], \theta)h(\vec{x}) \implies \max_{\theta \in \Theta} L(\vec{x}, \theta) = h(\vec{x}) \max_{\theta \in \Theta} g(T[\vec{x}], \theta) \implies \hat{\theta}_{MV} = \arg \max_{\theta \in \Theta} L(\vec{x}, \theta) = \arg \max_{\theta \in \Theta} g(T[\vec{x}], \theta)$
- si el EMV no es único, alguno puede no depender del suficiente:
 - $X \hookrightarrow U(\theta, \theta + 3) \implies \forall \lambda \in [0, 1], \lambda(X_{(n)} - 3) + (1 - \lambda)X_{(1)}$ es EMV
 - λ puede ser aleatoria, por ejemplo $\lambda = \frac{X_1^2}{X_1^2 + X_2^2}$, y entonces ese EMV no es función sólo del estadígrafo suficiente $(X_{(1)}, X_{(n)})$
- el EMV puede no ser suficiente; ejemplo:
 - $X \hookrightarrow U(\theta, 2\theta) \implies L(\vec{x}, \theta) = \frac{1}{\theta^n} I\left(\frac{x_{(n)}}{2} < \theta < x_{(1)}\right) \implies \begin{cases} (X_{(1)}, X_{(n)}) \text{ es suficiente} \\ \hat{\theta}_{MV} = \frac{X_{(n)}}{2} \end{cases}$
 - $\hat{\theta}_{MV}$ no es suficiente

3.2.2. equivarianza o invariancia funcional

- $\hat{\theta}$ es EMV de $\theta \implies h(\hat{\theta})$ es EMV de $h(\theta)$
 - h biyectiva
 - sea $\eta = h(\theta)$
 - $\hat{\eta}_{MV} = \arg \sup_{\eta} L(\vec{x}, h^{-1}[\eta])$
 - $\hat{\theta}_{MV} = \arg \sup_{\theta} L(\vec{x}, \theta) \implies h^{-1}(\eta) = \hat{\theta}_{MV}$ maximiza $L(\vec{x}, h^{-1}[\eta]) \implies h^{-1}(\hat{\eta}_{MV}) = \hat{\theta}_{MV} \implies \hat{\eta}_{MV} = h(\hat{\theta}_{MV})$
 - h cualquiera
 - $\hat{\eta}_{MV} = h(\hat{\theta})$ maximiza la verosimilitud perfilada

$$\mathcal{L}(\vec{x}, \eta) = \sup \{L(\vec{x}, \theta) \mid \theta \in h^{-1}(\eta)\}$$

- por ejemplo, $X \hookrightarrow N(\mu, \sigma) \implies \widehat{\sigma^2}_{MV} = s^2 \implies \hat{\sigma}_{MV} = s$

3.2.3. comportamiento asintótico

1. condiciones de regularidad

- a) $\theta \neq \theta' \implies F_{\theta} \neq F_{\theta'}$; si no, no podrían distinguirse y el estimador no podría ser consistente
- b) el soporte $\{x : f(x, \theta) > 0\}$ no cambia (no depende de θ)
- c) \vec{X} es una muestra aleatoria simple de $X \hookrightarrow F_{\theta_0}$
- d) el espacio paramétrico Θ es un intervalo abierto
- e) $\forall x, f(x, \theta)$ es derivable dos veces respecto a θ
- f) las integrales $\int \left| \frac{\partial^i f(x, \theta)}{\partial \theta^i} \right| dx$ son finitas para $i = 1, 2$

2. teorema de consistencia

- si se cumplen las condiciones de regularidad, entonces existe una sucesión de raíces de la ecuación de verosimilitud, $\hat{\theta}_n$, fuertemente consistente, es decir, tal que $\hat{\theta}_n \xrightarrow{\text{c.s.}} \theta_0$

3. teorema de eficiencia

a) enunciado: Si

- se cumplen las condiciones de regularidad
- existe $\frac{\partial^3 \ln f(x, \theta)}{\partial \theta^3}$ con $\left| \frac{\partial^3 \ln f(x, \theta)}{\partial \theta^3} \right| < K(x)$ siendo $E_\theta[K(X)] < \infty$

entonces

- existe una sucesión de raíces de la ecuación de verosimilitud, $\hat{\theta}_n$, consistente y asintóticamente gaussiana, es decir, $(\hat{\theta}_n - \theta_0)\sqrt{nI(\theta_0)} \xrightarrow{L} N(0, 1)$
- equivalentemente, con n grande $\hat{\theta}_n \overset{\sim}{\rightarrow} N\left(\theta_0, \frac{1}{\sqrt{nI(\theta_0)}}\right)$

donde $I(\theta) = \text{Var}\left(\frac{\partial \ln f(X, \theta)}{\partial \theta}\right) = E\left[\left(\frac{\partial \ln f(X, \theta)}{\partial \theta}\right)^2\right] = -E\left(\frac{\partial^2 \ln f(X, \theta)}{\partial \theta^2}\right)$ es la cantidad información de Fisher que X contiene sobre θ .

b) demostración:

- $u(\theta) = \frac{\partial \ln L(\vec{x}, \theta)}{\partial \theta} = \sum_{i=1}^n \frac{\partial \ln f(x_i, \theta)}{\partial \theta}$
- $E[u(\theta)] = \sum_{i=1}^n E\left(\frac{\partial \ln f(X_i, \theta)}{\partial \theta}\right)$
- $E\left(\frac{\partial \ln f(X, \theta)}{\partial \theta}\right) = \int \frac{\partial \ln f(x, \theta)}{\partial \theta} f(x, \theta) dx = \int \frac{1}{f(x, \theta)} \frac{\partial f(x, \theta)}{\partial \theta} f(x, \theta) dx = \int \frac{\partial f(x, \theta)}{\partial \theta} dx = \frac{\partial \int f(x, \theta) dx}{\partial \theta} = \frac{\partial 1}{\partial \theta} = 0$
- $\text{Var}[u(\theta)] = \text{Var}\left(\sum_{i=1}^n \frac{\partial \ln f(X_i, \theta)}{\partial \theta}\right) = \sum_{i=1}^n \text{Var}\left(\frac{\partial \ln f(X_i, \theta)}{\partial \theta}\right) = \sum_{i=1}^n E\left[\left(\frac{\partial \ln f(X_i, \theta)}{\partial \theta}\right)^2\right]$
- $E\left[\left(\frac{\partial \ln f(X, \theta)}{\partial \theta}\right)^2\right] = \int \left(\frac{\partial \ln f(x, \theta)}{\partial \theta}\right)^2 f(x, \theta) dx = \int \left(\frac{1}{f(x, \theta)} \frac{\partial f(x, \theta)}{\partial \theta}\right)^2 f(x, \theta) dx = \int \frac{1}{f(x, \theta)^2} \left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2 f(x, \theta) dx = \int \frac{1}{f(x, \theta)} \left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2 dx$
- $E\left(\frac{\partial^2 \ln f(X, \theta)}{\partial \theta^2}\right) = \int \frac{\partial^2 \ln f(x, \theta)}{\partial \theta^2} f(x, \theta) dx = \int \frac{\partial}{\partial \theta} \left(\frac{\partial \ln f(x, \theta)}{\partial \theta}\right) f(x, \theta) dx = \int \frac{\partial}{\partial \theta} \left(\frac{1}{f(x, \theta)} \frac{\partial f(x, \theta)}{\partial \theta}\right) f(x, \theta) dx = \int \frac{\frac{\partial^2 f(x, \theta)}{\partial \theta^2} f(x, \theta) - \left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2}{f(x, \theta)^2} f(x, \theta) dx = \int \frac{\frac{\partial^2 f(x, \theta)}{\partial \theta^2} f(x, \theta) - \left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2}{f(x, \theta)} dx = \int \frac{\partial^2 f(x, \theta)}{\partial \theta^2} dx - \int \frac{\left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2}{f(x, \theta)} dx = \frac{\partial^2 1}{\partial \theta^2} - \int \frac{\left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2}{f(x, \theta)} dx = 0 - \int \frac{\left(\frac{\partial f(x, \theta)}{\partial \theta}\right)^2}{f(x, \theta)} dx = -E\left[\left(\frac{\partial \ln f(X, \theta)}{\partial \theta}\right)^2\right]$
- luego $u(\theta)$ tiene esperanza y varianza finitas
- sea $\hat{\theta}_n$ una raíz de la ecuación de verosimilitud, $0 = u(\hat{\theta}_n)$
- desarrollo de Taylor de $u(\hat{\theta}_n)$ en torno a θ_0 : $0 = u(\hat{\theta}_n) = u(\theta_0) + (\hat{\theta}_n - \theta_0)u'(\theta_0) + (\hat{\theta}_n - \theta_0)^2 \frac{u''(\tilde{\theta})}{2}$ con $\tilde{\theta}$ tal que $|\tilde{\theta} - \theta_0| < |\hat{\theta}_n - \theta_0|$
- $0 = u(\theta_0) + (\hat{\theta}_n - \theta_0) \left[u'(\theta_0) + (\hat{\theta}_n - \theta_0) \frac{u''(\tilde{\theta})}{2}\right] \implies \hat{\theta}_n - \theta_0 = \frac{-u(\theta_0)}{u'(\theta_0) + (\hat{\theta}_n - \theta_0) \frac{u''(\tilde{\theta})}{2}} \implies \sqrt{n}(\hat{\theta}_n - \theta_0) = \frac{-\sqrt{n}u(\theta_0)}{u'(\theta_0) + (\hat{\theta}_n - \theta_0) \frac{u''(\tilde{\theta})}{2}} = \frac{-\sqrt{n}u(\theta_0)}{u'(\theta_0) + (\hat{\theta}_n - \theta_0) \frac{u''(\tilde{\theta})}{2n}}$
- numerador $\sqrt{n} \frac{-u(\theta_0)}{n}$: por el TCL, como $\frac{\partial \ln f(X_i, \theta)}{\partial \theta}$ son i.i.d. con esperanza 0 y varianza $I(\theta)$, se tiene $-\sqrt{n} \frac{u(\theta_0)}{n} = -\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n \frac{\partial \ln f(X_i, \theta)}{\partial \theta} \Big|_{\theta=\theta_0}\right) \xrightarrow{L} N\left(0, \sqrt{I(\theta_0)}\right)$
- denominador converge en probabilidad a $I(\theta_0)$:
 - por la LFGN $\frac{u'(\theta_0)}{n} = \frac{1}{n} \sum_{i=1}^n \frac{\partial^2 \ln f(X_i, \theta)}{\partial \theta^2} \Big|_{\theta=\theta_0} \xrightarrow{\text{c.s.}} -I(\theta_0)$

- se sabe que existe sucesión de soluciones de la ecuación de verosimilitud tal que $\hat{\theta}_n - \theta_0 \xrightarrow{P} 0$
- $\frac{u''(\hat{\theta})}{n} = \frac{1}{n} \sum_{i=1}^n \frac{\partial^3 \ln f(X_i, \theta)}{\partial \theta^3} \Big|_{\theta=\hat{\theta}} \implies \left| \frac{u''(\hat{\theta})}{n} \right| \leq \frac{1}{n} \sum_{i=1}^n \left| \frac{\partial^3 \ln f(X_i, \theta)}{\partial \theta^3} \Big|_{\theta=\hat{\theta}} \right| \leq \frac{1}{n} \sum_{i=1}^n K(X_i)$
 $\xrightarrow{\text{c.s.}} E[K(X)] = k < \infty \implies \text{con } n \text{ grande, } \left| \frac{1}{n} \sum_{i=1}^n K(X_i) - k \right| < \varepsilon \implies \text{con } n \text{ grande, } \frac{1}{n} \sum_{i=1}^n K(X_i) < k + \varepsilon \implies \text{con } n \text{ grande, } \left| \frac{u''(\hat{\theta})}{n} \right| < k + \varepsilon$
- $(\hat{\theta}_n - \theta_0) \frac{u''(\hat{\theta})}{2n} \xrightarrow{P} 0$
- $\frac{u'(\theta_0)}{n} + (\hat{\theta}_n - \theta_0) \frac{u''(\hat{\theta})}{2n} \xrightarrow{P} -I(\theta_0)$
- $I(\theta_0) > 0 \implies \frac{1}{\frac{u'(\theta_0)}{n} + (\hat{\theta}_n - \theta_0) \frac{u''(\hat{\theta})}{2n}} \xrightarrow{P} \frac{-1}{I(\theta_0)}$
- $\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{L} N\left(0, \frac{1}{\sqrt{I(\theta_0)}}\right)$

c) corolario: En las condiciones del teorema anterior, si la ecuación de verosimilitud tiene una única raíz, ésta es el EMV y es consistente, asintóticamente eficiente y asintóticamente gaussiano.

d) ejemplo

- $X \hookrightarrow \text{Exp}(\theta)$
- el EMV es $\hat{\theta}_{\text{MV}} = \frac{1}{X}$
- la información de Fisher es $\frac{-\partial^2 \ln f(x, \theta)}{\partial \theta^2} = \frac{-\partial^2 \ln(\theta e^{-\theta x})}{\partial \theta^2} = \frac{1}{\theta^2}$
- se verifican las condiciones de regularidad de F-C-R
- además, $\frac{\partial^3 f(x, \theta)}{\partial \theta^3} = \frac{\partial^3 \ln(\theta e^{-\theta x})}{\partial \theta^3} = \frac{2}{\theta^3}$
- considerando que el espacio paramétrico es $\Theta = (\epsilon, \infty)$, entonces $\theta > \epsilon$ y $\frac{\partial^3 f(x, \theta)}{\partial \theta^3} = \frac{2}{\theta^3} < \frac{2}{\epsilon^3}$
- por el teorema, $\sqrt{n} \left(\frac{1}{X} - \theta \right) \xrightarrow{L} N(0, \theta)$
- aunque la acotación de la tercera derivada no se verifica para cualquier $\theta > 0$, basta suponer en la práctica el ϵ muy pequeño, o emplear directamente el método delta con $g(x) = \frac{1}{x}$:
 - por el TCL, $\sqrt{n}(\bar{X} - \mu) \xrightarrow{L} N(0, \mu)$ con $\mu = \frac{1}{\theta}$
 - luego $\sqrt{n} \left(\frac{1}{X} - \frac{1}{\mu} \right) = \sqrt{n} \left(\frac{1}{X} - \theta \right) \xrightarrow{L} N(0, \theta)$

e) ejemplo

- $X \hookrightarrow U(0, \theta)$
- EMV $\hat{\theta}_n = X_{(n)}$ cuya distribución es

$$F_{X_{(n)}}(x) = \Pr(X_{(n)} \leq x) = \begin{cases} 0 & x \leq 0 \\ \left(\frac{x}{\theta}\right)^n & 0 < x < \theta \\ 1 & x \geq \theta \end{cases}$$

- $E(X_{(n)}) = \frac{n}{n+1} \theta \rightarrow \theta$
- $\text{Var}(X_{(n)}) = \left(\frac{n}{n+2} - \frac{n^2}{(n+1)^2} \right) \theta^2 = \frac{n}{(n+2)(n+1)^2} \theta^2 \rightarrow 0$
- luego EMV consistente pero $\sqrt{n}(X_{(n)} - \theta)$ no converge a una ley gaussiana pues
 - su varianza tiende a cero: $\text{Var}[\sqrt{n}(X_{(n)} - \theta)] = \left(\frac{n^2}{n+2} - \frac{n^3}{(n+1)^2} \right) \theta^2 = \frac{n^2 \theta^2}{n^3 + 4n^2 + 5n + 2} \rightarrow 0$
 - luego $\sqrt{n}(X_{(n)} - \theta)$ tiende a una degenerada en cero, $\sqrt{n}(X_{(n)} - \theta) \xrightarrow{\text{Pr}} 0$:
 - directamente: $\forall \epsilon > 0, \Pr[|\sqrt{n}(X_{(n)} - \theta)| < \epsilon] = \Pr[\sqrt{n}(\theta - X_{(n)}) < \epsilon] = \Pr\left[X_{(n)} > \theta - \frac{\epsilon}{\sqrt{n}}\right] = 1 - F_{X_{(n)}}\left(\theta - \frac{\epsilon}{\sqrt{n}}\right) = 1 - \left[\frac{\theta - \frac{\epsilon}{\sqrt{n}}}{\theta}\right]^n = 1 - \left[1 - \frac{\epsilon}{\theta\sqrt{n}}\right]^n =$

$$1 - \left(\underbrace{\left[1 - \frac{\epsilon}{\theta\sqrt{n}} \right]}_{\xrightarrow{n} e^{-\epsilon/\theta} < 1} \right)^{\sqrt{n}} \stackrel{\substack{\exists \delta, n_0 \\ \forall n > n_0}}{\geq} 1 - \underbrace{\left(e^{-\epsilon/\theta} + \delta \right)}_{\xrightarrow{n} 0}^{\sqrt{n}} \xrightarrow{n} 1$$

◦ otramte, mediante la desigualdad de Márkov: sea $T = \sqrt{n}(X_{(n)} - \theta)$; $\Pr[|T| \leq \epsilon] =$

$$\Pr[T^2 \leq \epsilon^2] \geq 1 - \frac{E[T^2]}{\epsilon^2} = 1 - \frac{\text{Var}[T] + E^2[T]}{\epsilon^2} = 1 - \frac{\text{Var}[T] + (\sqrt{n} \frac{-1}{n+1} \theta)^2}{\epsilon^2} \xrightarrow{n} 1 - 0 = 1$$

- multiplicando por n en vez de por \sqrt{n} se consigue que la varianza no se anule: $\text{Var}[n(X_{(n)} - \theta)] = \left(\frac{n^3}{n+2} - \frac{n^4}{(n+1)^2} \right) \theta^2 = \frac{n^3 \theta^2}{n^3 + 4n^2 + 5n + 2} \rightarrow \theta^2$
- considérese la convergencia en ley de $\frac{X_{(n)} - \theta}{\theta/n}$
 - $\lim_{n \rightarrow \infty} F_{\frac{X_{(n)} - \theta}{\theta/n}}(x) = \lim_n \Pr \left[\frac{X_{(n)} - \theta}{\theta/n} \leq x \right]$
 - si $x \geq 0$ entonces $\Pr \left[\frac{X_{(n)} - \theta}{\theta/n} \leq x \right] = 1$
 - si $x < 0$ entonces $\lim_n \Pr \left[\frac{X_{(n)} - \theta}{\theta/n} \leq x \right] = \lim_n \Pr [X_{(n)} \leq (\frac{x}{n} + 1)\theta]$
 $= \lim_n \Pr \left[\frac{X_{(n)}}{\theta} \leq \frac{x}{n} + 1 \right] = \langle Y \leftrightarrow U(0, 1) \rangle = \lim_n \Pr [Y_{(n)} \leq \frac{x}{n} + 1] =$
 $\lim_n (\Pr [Y \leq \frac{x}{n} + 1])^n = \lim_n \left(\frac{x}{n} + 1 \right)^n = \lim_n \left(1 + \frac{x}{n} \right)^n = e^x$
 - $\frac{X_{(n)} - \theta}{\theta/n} \hookrightarrow -\text{Exp}(1)$ distribución asintótica no gausiana