

# 1 Consistencia de M-estimadores

Supongamos que se tiene una familia de densidades  $p(x, \theta)$  discreta o continua donde  $\theta \in \Theta \subset R$ . Tomemos una función  $\psi(x, \theta) : R^2 \rightarrow R$  y llamemos  $\eta(\theta, \theta^*) = E_\theta(\psi(x, \theta^*))$ . Supondremos que para todo  $\theta \in \Theta$  se cumple

$$\eta(\theta, \theta) = 0$$

Esta condición será llamada "consistencia de Fisher".

Dada una muestra aleatoria  $X_1, \dots, X_n$  de  $p(x, \theta)$ , el correspondiente M-estimador  $\hat{\theta}_n$  de  $\theta$  se define como la solución de

$$\sum_{i=1}^n \psi(X_i, \hat{\theta}_n) = 0 \tag{1}$$

**Teorema.** Supongamos que  $\psi(x, \theta)$  es estrictamente monótona (creciente o decreciente) y continua respecto de  $\theta$ . Sea  $X_1, \dots, X_n$  una muestra aleatoria con densidad  $p(x, \theta_0)$ . Luego  $\hat{\theta}_n$  converge a  $\theta$  casi seguramente.

Demostración

Vamos a suponer que  $\psi(x, \theta)$  es estrictamente creciente como función de  $\theta$ . La demostración para el caso decreciente es similar. Llamemos

$$\eta(\theta, \theta^*) = E_\theta(\psi(x, \theta^*))$$

Es inmediato que  $\eta(\theta, \theta^*)$  es estrictamente monótona como función de  $\theta^*$

$\hat{\theta}_n$  está definido por

$$\frac{1}{n} \sum_{i=1}^n \psi(X_i, \hat{\theta}_n) = 0$$

Sea

$$L_n(\theta) = \frac{1}{n} \sum_{i=1}^n \psi(X_i, \theta)$$

Tomemos  $\varepsilon > 0$ , vamos a mostrar que con probabilidad 1 existe  $n_0$  tal que para  $n \geq n_0$  se tiene

$$\theta_0 - \varepsilon \leq \hat{\theta}_n \leq \theta_0 + \varepsilon$$

Por la monotonía de  $\eta$  tenemos

$$\eta(\theta_0, \theta_0 - \varepsilon) < \eta(\theta_0, \theta_0) = 0 < \eta(\theta_0, \theta_0 + \varepsilon)$$

Definamos

$$\delta = \min(\eta(\theta_0, \theta_0 + \varepsilon), -\eta(\theta_0, \theta_0 - \varepsilon)).$$

Luego  $\delta > 0$  y

$$\eta(\theta_0, \theta_0 - \varepsilon) \leq -\delta \leq \delta \leq \eta(\theta_0, \theta_0 + \varepsilon)$$

Como  $L_n(\theta_0 + \varepsilon)$  converge casi seguramente a  $\eta(\theta_0, \theta_0 + \varepsilon)$  con probabilidad 1 existe  $n_1$  tal que para todo  $n \geq n_1$

$$L_n(\theta_0 + \varepsilon) \geq \delta/2$$

y como  $L_n(\theta_0 - \varepsilon)$  converge casi seguramente a  $\eta(\theta_0, \theta_0 - \varepsilon)$  existe  $n_2$  tal que para todo  $n \geq n_2$

$$L_n(\theta_0 - \varepsilon) \leq -\delta/2$$

Luego como  $L_n$  es estrictamente creciente y continua, si  $n_0 = \max(n_1, n_2)$ , para todo  $n \geq n_0$  existe un único valor  $\hat{\theta}_n$  tal que  $L_n(\hat{\theta}_n) = 0$  y ese valor tiene que satisfacer  $\theta_0 + \varepsilon \leq \hat{\theta}_n \leq \theta_0 - \varepsilon$ .

### 1.1 Estimadores basados en momentos.

El estimador de los momentos se define por

$$\frac{1}{n} \sum_{i=1}^n g(x_i) = E_\theta(g(x_i))$$

Luego si definimos

$$\psi(x_i, \theta) = g(x_i) - E_\theta(g(x_i))$$

tenemos

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n (g(x_i) - E_\theta(g(x_i))) &= 0 \\ \frac{1}{n} \sum_{i=1}^n \psi(x_i, \theta) &= 0 \end{aligned}$$

Observemos que se tiene

$$\eta(\theta, \theta) = E_\theta(\psi(x, \theta)) = E_\theta(g(x)) - E_\theta(g(x)) = 0$$

y por lo tanto se cumple la condición de consistencia de Fisher. Para que se cumpla la consistencia habrá que pedir que  $E_\theta(g(x))$  sea una función continua y estrictamente creciente.

### 1.2 Estimador de máxima verosimilitud.

El estimador de máxima verosimilitud satisface

$$\frac{1}{n} \sum \psi_0(x_i, \theta) = 0$$

con

$$\psi_0(x, \theta) = \frac{\partial \log(p(x, \theta))}{\partial \theta} \tag{2}$$

Hemos mostrado que bajo las condiciones de la desigualdad de Rao-Cramer  $\eta(\theta, \theta) = E_{\theta}(\psi_0(x, \theta)) = 0$ . Luego si  $\psi_0$  es estrictamente monótona y continua, también es fuertemente consistente. La hipótesis de continuidad y monotonicidad pueden relajarse. También la consistencia fuerte es válida para el caso que se estimen varios parámetros simultáneamente.

## 2 Asintótica normalidad de los M-estimadores.

Consideremos un M-estimador  $\hat{\theta}_n$  definido por (1)

**Teorema.** Supongamos que

(1)  $\psi(x, \theta)$  tiene dos derivadas continuas respecto de  $\theta$ .

(2)  $\hat{\theta}_n \xrightarrow{p} \theta_0$

(3)

$$E_{\theta_0}(\psi^2(x, \theta_0)) < \infty$$

(4)

$$E\left(\frac{\partial\psi(x_i, \theta_0)}{\partial\theta}\right) \neq 0$$

(5) Existe  $\varepsilon > 0$  y  $\zeta(x)$  tal que

$$\sup_{|\theta - \theta_0| \leq \varepsilon} \left| \frac{\partial^2\psi(x_i, \theta_0)}{\partial\theta^2} \right| \leq \zeta(x)$$

y

$$E(\zeta(x)) < \infty$$

Luego se tiene que

$$n^{1/2}(\hat{\theta}_n - \theta_0) \xrightarrow{\mathcal{D}} N\left(0, \frac{A(\psi, \theta_0)}{B^2(\psi, \theta_0)}\right)$$

donde

$$A(\psi, \theta) = E_{\theta}(\psi^2(x, \theta))$$

y

$$B(\psi, \theta) = E\left(\frac{\partial\psi(x, \theta)}{\partial\theta}\right) \quad (3)$$

**Demostración**

Tenemos

$$\sum_{i=1}^n \psi(x_i, \hat{\theta}_n) = 0$$

y luego desarrollando en serie de Taylor en el punto  $\theta_0$  se tiene

$$\begin{aligned} 0 &= \sum_{i=1}^n \psi(x_i, \hat{\theta}_n) = \left(\sum_{i=1}^n \psi(x_i, \theta_0)\right) + \left(\sum_{i=1}^n \frac{\partial\psi(x_i, \theta_0)}{\partial\theta}\right) (\hat{\theta}_n - \theta_0) \\ &\quad + \frac{1}{2} \left(\sum_{i=1}^n \frac{\partial^2\psi(x_i, \theta_n^*)}{\partial\theta^2}\right) (\hat{\theta}_n - \theta_0)^2 \end{aligned}$$

Por lo tanto

$$-\sum_{i=1}^n \psi(x_i, \theta_0) = \left[ \left( \sum_{i=1}^n \frac{\partial \psi(x_i, \theta_0)}{\partial \theta} \right) + \frac{1}{2} \left( \left( \sum_{i=1}^n \frac{\partial^2 \psi(x_i, \theta_n^*)}{\partial \theta^2} \right) (\hat{\theta}_n - \theta_0) \right) \right] (\hat{\theta}_n - \theta_0)$$

y por lo tanto

$$(\hat{\theta}_n - \theta_0) = \frac{-\sum_{i=1}^n \psi(x_i, \theta_0)}{\left( \sum_{i=1}^n \frac{\partial \psi(x_i, \theta_0)}{\partial \theta} \right) + \frac{\hat{\theta}_n - \theta_0}{2} \left( \sum_{i=1}^n \frac{\partial^2 \psi(x_i, \theta_n^*)}{\partial \theta^2} \right)}$$

y

$$\begin{aligned} n^{1/2}(\hat{\theta}_n - \theta_0) &= \frac{n^{-1/2} \sum_{i=1}^n -\psi(x_i, \theta_0)}{\frac{1}{n} \left( \sum_{i=1}^n \frac{\partial \psi(x_i, \theta_0)}{\partial \theta} \right) + \frac{1}{2n} \left( \left( \sum_{i=1}^n \frac{\partial^2 \psi(x_i, \theta_n^*)}{\partial \theta^2} \right) (\hat{\theta}_n - \theta_0) \right)} \\ &= \frac{A_n}{B_n + C_n} \end{aligned} \quad (4)$$

donde

$$A_n = n^{-1/2} \sum_{i=1}^n -\psi(x_i, \theta_0)$$

$$B_n = \frac{1}{n} \left( \sum_{i=1}^n \frac{\partial \psi(x_i, \theta_0)}{\partial \theta} \right)$$

y

$$C_n = \frac{\hat{\theta}_n - \theta_0}{2n} \left( \sum_{i=1}^n \frac{\partial^2 \psi(x_i, \theta_n^*)}{\partial \theta^2} \right)$$

Vamos a mostrar que

$$A \xrightarrow{\mathcal{D}} N(0, A(\psi, \theta_0)), \quad (5)$$

$$B_n \xrightarrow{c.s.} B(\psi, \theta_0), \quad (6)$$

y

$$C_n \xrightarrow{p} 0 \quad (7)$$

Comencemos mostrando (5). Esto se deduce inmediatamente del Teorema Central del Límite observando que

$$E_{\theta_0}(-\psi(x_i, \theta_0)) = 0 \quad \text{y} \quad \text{var}_{\theta_0}(-\psi(x_i, \theta_0)) = A(\psi, \theta_0)$$

Por otro lado (6) se deduce inmediatamente de la Ley Fuerte de los Grandes Números.

Llamemos

$$D_n = \frac{1}{2n} \left| \sum_{i=1}^n \frac{\partial^2 \psi(x_i, \theta_n^*)}{\partial \theta^2} \right|$$

Sea  $U_n = \{|\widehat{\theta}_n - \theta| \leq \varepsilon\}$  y sea  $h = \frac{1}{2}E(\zeta(x))$ . Tenemos que

$$\begin{aligned} D_n I_{U_n} &\leq \frac{1}{2n} \left( \sum_{i=1}^n \left| \frac{\partial^2 \psi(x_i, \theta_n^*)}{\partial \theta^2} \right| I_{U_n} \right) \\ &\leq \frac{1}{2n} \left( \sum_{i=1}^n \sup_{|\theta - \theta_0| \leq \varepsilon} \left| \frac{\partial^2 \psi(x_i, \theta)}{\partial \theta^2} \right| \right) \\ &\leq \frac{1}{2n} \left( \sum_{i=1}^n \zeta(x_i) \right) = F_n \end{aligned}$$

Llamemos  $U_n^c$  al complemento de  $U_n$ . Luego

$$\begin{aligned} P(D_n \geq h + 1) &= P(\{D_n I_{U_n} \geq h + 1\} + P(D_n I_{U_n^c} \geq h + 1\}) \\ &\leq P(F_n \geq h + 1) + P(U_n^c) \end{aligned}$$

Por la ley de los grandes números  $F_n \xrightarrow{c.s.} h$ , se tiene que

$$P(F_n \geq h + 1) \rightarrow 0$$

y por la hipótesis 2

$$P(U_n^c) \rightarrow 0$$

Luego

$$P(D_n \geq h + 1) \rightarrow 0 \tag{8}$$

Luego dado  $\delta > 0$

$$\{|C_n| > \delta\} \subset \{D_n \geq h + 1\} \cup \{|\theta_n - \theta_0| \geq \delta/(h + 1)\}$$

y por lo tanto

$$P(|C_n| > \delta) \leq P(D_n \geq h + 1) + P(|\theta_n - \theta_0| \geq \delta/(h + 1))$$

Usando (8) y la hipótesis (5) se tiene

$$P(C_n > \delta) \rightarrow 0$$

y por lo tanto (7) se cumple

De (4) (5), (6) y (7) por Slutsky resulta que

$$n^{1/2}(\widehat{\theta}_n - \theta_0) \xrightarrow{\mathcal{D}} N \left( 0, \frac{A(\psi, \theta_0)}{B^2(\psi, \theta_0)} \right)$$

## 2.1 Estimadores basados en momentos

Apliquemos el teorema a los estimadores basados en momentos.

Luego las hipótesis se transforman en

(1)  $E_{\theta}g(x, \theta)$  tiene dos derivadas continuas respecto de  $\theta$ .

(2)  $\hat{\theta}_n \xrightarrow{p} \theta_0$

(3)

$$E_{\theta_0}(g^2(x)) < \infty$$

(4)

$$E\left(\frac{\partial g(x_i, \theta_0)}{\partial \theta}\right) \neq 0$$

(5) Existe  $\varepsilon > 0$  tal que

$$\sup_{|\theta - \theta_0| \leq \varepsilon} \left| \frac{\partial^2 E_{\theta}(g(x))}{\partial \theta^2} \Big|_{\theta = \theta_0} \right| \leq \infty$$

En este caso

$$A(\psi, \theta) = \text{var}_{\theta}(g(x)) \quad \text{y} \quad B(\psi, \theta) = -E\left(\frac{\partial g(x_i, \theta_0)}{\partial \theta}\right)$$

## 2.2 Estimador de máxima verosimilitud

En el caso del estimador de máxima verosimilitud se tiene que  $\psi = \psi_0$  dada por 2) y luego

$$A(\psi_0, \theta) = I(\theta)$$

El siguiente teorema muestra quien es  $B(\psi_0, \theta)$ .

**Teorema.** Si se cumplen las hipótesis de Rao Cramer entonces  $B(\psi_0, \theta) = -I(\theta)$ .

Demostración. Tenemos que

$$E_{\theta}(\psi_0(x, \theta)) = 0$$

es decir

$$\int I_S(x) \frac{\delta \log(p(x, \theta))}{\partial \theta} p(x, \theta) dx = 0$$

donde  $S = \{x : p(x, \theta) > 0\}$ . Derivando nuevamente dentro de la integral se tiene

$$\int I_S(x) \frac{\delta^2 \log(p(x, \theta))}{\partial \theta^2} p(x, \theta) dx + \int I_S(x) \frac{\delta \log(p(x, \theta))}{\partial \theta} \frac{\partial p(x, \theta)}{\partial \theta} dx = 0 \quad (9)$$

Luego

$$\begin{aligned} \int I_S(x) \frac{\delta \log(p(x, \theta))}{\partial \theta} \frac{\partial p(x, \theta)}{\partial \theta} dx &= \int I_S(x) \left( \frac{\delta \log(p(x, \theta))}{\partial \theta} \right)^2 p(x, \theta) dx \\ &= E_\theta \left( \left( \frac{\delta \log(p(x, \theta))}{\partial \theta} \right)^2 \right) \\ &= I(\theta) \end{aligned}$$

y reemplazando en (9) se obtiene

$$\int I_S(x) \frac{\delta^2 \log(p(x, \theta))}{\partial \theta} p(x, \theta) dx = -I(\theta)$$

y luego

$$\begin{aligned} B(\psi_0, \theta) &= E_\theta \left( \frac{\partial \psi(x, \theta_0)}{\partial \theta} \right) \\ &= \int I_S(x) \frac{\delta^2 \log(p(x, \theta))}{\partial \theta} p(x, \theta) dx \\ &= -I(\theta) \end{aligned}$$

Esto demuestra el Teorema.

**Corolario.** Bajo las condiciones 1-5 y las hipótesis de Rao Cramer, el estimador de máxima verosimilitud  $\hat{\theta}_n$  satisface

$$n^{1/2}(\hat{\theta}_n - \theta_0) \xrightarrow{\mathcal{D}} N\left(0, \frac{1}{I(\theta)}\right)$$

El siguiente Teorema muestra que cualquier otro M-estimador tiene una varianza mayor que el estimador de máxima verosimilitud.

**Teorema.** Supongamos que se cumplan las condiciones de Rao Cramer.

Luego

(a) si  $\hat{\theta}_n$  es un M-estimador entonces

$$\frac{A(\psi, \theta)}{B^2(\psi, \theta)} \geq I(\theta)$$

(b) La igualdad se cumple si  $\hat{\theta}_n$  coincide con el M-estimador correspondiente a  $\psi(x, \theta)$  tal que

$$P(\psi(x, \theta) = \psi_0(x, \theta)) = 1$$

y luego  $\hat{\theta}_n$  coincide con probabilidad 1 con el estimador de máxima verosimilitud

Demostración. Como

$$E_{\theta}(\psi(x, \theta)) = \int I_S(x)\psi(x, \theta)p(x, \theta)dx = 0$$

derivando se obtiene

$$\int I_S \frac{\partial \psi(x, \theta_0)}{\partial \theta} p(x, \theta) dx + \int I_S(x)\psi(x, \theta) \frac{\partial p(x, \theta)}{\partial \theta} dx = 0$$

$$\begin{aligned} B(\psi, \theta) &= E_{\theta} \left( \frac{\partial \psi(x, \theta_0)}{\partial \theta} \right) \\ &= \int I_S \frac{\partial \psi(x, \theta_0)}{\partial \theta} p(x, \theta) dx \\ &= - \int I_S(x)\psi(x, \theta) \frac{\partial p(x, \theta)}{\partial \theta} dx \\ &= - \int I_S(x)\psi(x, \theta) \frac{\partial \log p(x, \theta)}{\partial \theta} p(x, \theta) dx \\ &\quad - \int I_S(x)\psi(x, \theta)\psi_0(x, \theta)p(x, \theta) dx \end{aligned}$$

Como  $E_{\theta}(\psi(x, \theta)) = E_{\theta}(\psi_0(x, \theta)) = 0$ , se tiene

$$B(\psi, \theta) = \text{cov}_{\theta}(\psi(x), \psi_0(x))$$

y por la desigualdad de Cauchy-Schwarz se tiene

$$B^2(\psi, \theta) \leq \text{var}_{\theta}(\psi(x))\text{var}_{\theta}(\psi_0(x))$$

Pero como  $\text{var}_{\theta}(\psi(x)) = A(\psi, \theta)$  y  $\text{var}_{\theta}(\psi_0(x)) = I(\theta)$  se tiene

$$B^2(\psi, \theta) \leq A(\psi, \theta)I(\theta)$$

y luego

$$\frac{A(\psi, \theta)}{B^2(\psi, \theta)} \geq I(\theta)$$

Esto prueba (a)

Para probar (b) observemos que la igualdad se cumple si y solo si

$$P_{\theta}(\psi(x) = A(\theta)\psi_0(x) + B(\theta)) = 1$$

Pero como

$$\begin{aligned} E_{\theta}(A(\theta)\psi_0(x) + B(\theta)) &= A(\theta)E_{\theta}(\psi_0(x)) + B(\theta) \\ &= B(\theta) = 0 \end{aligned}$$

Resulta que  $B(\theta) = 0$ . Pero es inmediato que  $A(\theta)\psi_0(x)$  define el mismo estimador que  $\psi_0(x)$ . Luego  $\hat{\theta}_n$  coincide con el estimador de máxima verosimilitud con probabilidad 1.