

Modelos Estadísticos para la Regresión y la Clasificación

Continuación Práctico 3 - Estimación de máxima verosimilitud

Micaela Long

Instituto de Matemática y Estadística Prof. Rafael Laguardia (IMERL)
Facultad de Ingeniería, Universidad de la República, Uruguay

6 de setiembre de 2024

Práctico 23/8:

- Práctico 2 Ejercicio 3: Descomposición de la varianza.
- Repaso teórico estimación
- Práctico 3 Ejercicio 1
- Práctico 3 Ejercicio 2
- Práctico 3 Ejercicio 3 (calculamos estimador de momentos)

Ejercicio 3: Momentos vs. Máxima Verosimilitud

Sea X_1, \dots, X_n un muestreo i.i.d. de una distribución normal $N(\theta, \theta)$.

- 1 Calcular los estimadores de momentos $\hat{\theta}_M$ y de máxima verosimilitud $\hat{\theta}_{MLE}$ de θ
- 2 Nos enfocamos en esta parte en el estimador de máxima verosimilitud.
 - a) Probar que $\hat{\theta}_{MLE}$ es sesgado pero asintóticamente insesgado
 - b) Probar que $\text{Var}(\hat{\theta}_{MLE})$ alcanza la cota de Cramér-Rao.

- **Momento**: esperanza de una potencia de una variable aleatoria.
- Momento de primer orden es $\mathbb{E}(X)$, el momento de segundo orden es $\mathbb{E}(X^2)$, etc.
- Estimador de momentos se basa en la idea de hacer coincidir los **momentos muestrales** (medidas estadísticas calculadas a partir de los datos) con los **momentos poblacionales** (valores esperados derivados de la distribución teórica) para encontrar el parámetro desconocido.

$$\mathbb{E}(X) = \frac{1}{n} \sum_{i=1}^n X_i$$

- En nuestro ejercicio $\theta = \mathbb{E}(X)$, por lo que el estimador de momentos es:

$$\hat{\theta}_M = \frac{1}{n} \sum_{i=1}^n X_i$$

En otros ejemplos podríamos necesitar momentos de mayor orden.

Queremos encontrar el estimador MLE:

$$\hat{\theta}_{MLE} = \arg \max_{\theta} \mathcal{L}(\theta) = \arg \max_{\theta} \log(\mathcal{L}(\theta))$$

Para todo i se tiene $X_i \sim \mathcal{N}(\theta, \theta)$, luego

$$f_{\theta}(x_i) = \frac{1}{\sqrt{2\pi\theta}} e^{-\frac{1}{2} \frac{(x_i - \theta)^2}{\theta}}$$

La función de verosimilitud es:

$$\mathcal{L}(\theta) = \prod_{i=1}^n f_{\theta}(x_i) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\theta}} e^{-\frac{1}{2} \frac{(x_i - \theta)^2}{\theta}}$$

Vamos a maximizar la log verosimilitud

$$l(\theta) = \log(\mathcal{L}(\theta)) = \log \left[\prod_{i=1}^n \frac{1}{\sqrt{2\pi\theta}} e^{-\frac{1}{2} \frac{(x_i - \theta)^2}{\theta}} \right] = -\frac{n}{2} \log(2\pi\theta) + \sum \frac{-\frac{1}{2}(X_i - \theta)^2}{\theta}$$

Para hallar el máximo derivamos $l(\theta)$ e igualamos a 0

$$0 = \frac{\partial l(\theta)}{\partial \theta} = -\frac{n}{2\theta} + \frac{1}{2\theta^2} \sum_{i=1}^n X_i^2 - \frac{n}{2}$$

Esto se cumple si y solo si

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

Luego, como $\theta = \text{Var}(X_i) > 0$

$$\hat{\theta}_{MLE} = -\frac{1}{2} + \sqrt{\frac{1}{4} + \sum_{i=1}^n \frac{X_i^2}{n}}$$

Ejercicio 3

Parte 2

Queremos ver que el estimador es:

- 1 Sesgado
- 2 Asintóticamente insesgado
- 3 Asintóticamente eficiente (alcanza la cota de CR en el límite)

1) Para ver que es sesgado, calculamos $\mathbb{E}(\hat{\theta}_{MLE})$

$$\begin{aligned}\mathbb{E}(\hat{\theta}_{MLE}) &= \mathbb{E}\left(-\frac{1}{2} + \sqrt{\frac{1}{4} + \sum_{i=1}^n \frac{X_i^2}{n}}\right) \stackrel{(1)}{<} -\frac{1}{2} + \sqrt{\frac{1}{4} + \sum_{i=1}^n \frac{\mathbb{E}(X_i^2)}{n}} \\ &\stackrel{(2)}{=} -\frac{1}{2} + \sqrt{\frac{1}{4} + \sum_{i=1}^n \frac{\theta + \theta^2}{n}} \\ &= \theta\end{aligned}$$

donde en:

(1) usamos que \sqrt{x} es estrictamente cóncava, y que vale la **desigualdad de Jensen**: si f es estrictamente cóncava entonces $\mathbb{E}(f(X)) < f(\mathbb{E}(X))$

(2) $\mathbb{E}(X_i^2) = \text{Var}(X_i) + \mathbb{E}(X_i)^2 = \theta + \theta^2$.

Luego $\mathbb{E}(\hat{\theta}_{MLE}) \neq \theta$, por lo que el estimador es sesgado.

Ejercicio 3

Parte 2

2) Para ver que es asintóticamente insesgado, tenemos que considerar $\lim_{n \rightarrow \infty} \mathbb{E}(\hat{\theta}_{MLE})$.

$$\hat{\theta}_{MLE} = -\frac{1}{2} + \sqrt{\frac{1}{4} + \sum_{i=1}^n \frac{X_i^2}{n}} = -\frac{1}{2} + \sqrt{\frac{1}{4} + u} = g(u)$$

donde $u = \sum_{i=1}^n \frac{X_i^2}{n}$.

Notar que por la Ley (fuerte) de los Grandes Números (LGN), en un conjunto de probabilidad 1 vale

$$\begin{aligned} \lim_{n \rightarrow \infty} u &= \lim_{n \rightarrow \infty} \sum_{i=1}^n \frac{X_i^2}{n} = \mathbb{E}(X_i^2) \\ &= \text{Var}(X_i) + \mathbb{E}(X_i)^2 \\ &= \theta + \theta^2 \end{aligned}$$

Si definimos $u_0 = \theta + \theta^2$, podemos aproximar g por

$$g(u) \approx g(u_0) + g'(u_0)(u - u_0)$$

donde $g'(u) = \frac{1}{2\sqrt{\frac{1}{4} + u}}$.

Notar que estamos usando dos resultados importantes: el desarrollo de Taylor de orden 1, y la LGN.

Ejercicio 3

Parte 2

Es decir

$$\begin{aligned}\hat{\theta}_{MLE} &= g(u) \approx g(u_0) + g'(u_0)(u - u_0) \\ &= -\frac{1}{2} + \sqrt{\frac{1}{4} + u_0} + \frac{1}{2\sqrt{\frac{1}{4} + u_0}} (u - u_0) \\ &= -\frac{1}{2} + \sqrt{\frac{1}{4} + \theta + \theta^2} + \frac{1}{2\sqrt{\frac{1}{4} + \theta + \theta^2}} \left(\sum_{i=1}^n \frac{X_i^2}{n} - (\theta + \theta^2) \right) \\ &= \theta + \frac{1/2}{\theta + 1/2} \left(\sum_{i=1}^n \frac{X_i^2}{n} - (\theta + \theta^2) \right)\end{aligned}$$

Luego

$$\begin{aligned}\mathbb{E}(\hat{\theta}_{MLE}) &\xrightarrow{n \rightarrow \infty} \mathbb{E} \left(\theta + \frac{1/2}{\theta + 1/2} \left(\sum_{i=1}^n \frac{X_i^2}{n} - (\theta + \theta^2) \right) \right) \\ &= \theta + \frac{1/2}{\theta + 1/2} \left(\sum_{i=1}^n \frac{\mathbb{E}(X_i^2)}{n} - (\theta + \theta^2) \right) \\ &= \theta\end{aligned}$$

Entonces $\hat{\theta}_{MLE}$ es asintóticamente insesgado.

Ejercicio 3

Parte 2

3) De la misma calculamos $\text{Var}(\hat{\theta}_{MLE})$

$$\begin{aligned}\text{Var}(\hat{\theta}_{MLE}) &\approx \text{Var}\left(\theta + \frac{1/2}{\theta + 1/2} \left(\sum_{i=1}^n \frac{X_i^2}{n} - (\theta + \theta^2)\right)\right) \\ &= \left(\frac{1/2}{\theta + 1/2}\right)^2 \text{Var}\left(\sum_{i=1}^n \frac{X_i^2}{n} - (\theta + \theta^2)\right) \\ &= \left(\frac{1/2}{\theta + 1/2}\right)^2 \sum_{i=1}^n \frac{\text{Var}(X_i^2)}{n^2} \\ &= \frac{1/4}{n(\theta + 1/2)^2} \text{Var}(X_i^2)\end{aligned}$$

Para calcular $\text{Var}(X_i^2)$ usamos la siguiente propiedad:

$$Z \sim \mathcal{N}(\mu, \sigma^2) \Rightarrow \text{Var}(Z^2) = 4\mu^2\sigma^2 + 2\sigma^4$$

Luego, como $X_i \sim \mathcal{N}(\theta, \theta)$

$$\begin{aligned}\text{Var}(\hat{\theta}_{MLE}) &\approx \frac{1/4}{n(\theta + 1/2)^2} (4\theta^3 + 2\theta^2) = \frac{1/4}{n(\theta + 1/2)^2} 4\theta^2 \left(\theta + \frac{1}{2}\right) \\ &= \frac{\theta^2}{n(\theta + 1/2)}\end{aligned}$$

En el límite la aproximación es una igualdad.

Ejercicio 3

Parte 2

Queda probar que la cota de Cramér-Rao es $\frac{\theta^2}{n(\theta+1/2)}$. Recordar que la cota de CR es:

$$\text{Var}(\hat{\theta}) \geq \frac{1}{\mathcal{I}(\theta)} = \frac{1}{-\mathbb{E}\left(\frac{\partial^2 l(\theta)}{\partial \theta^2}\right)}$$

Antes calculamos

$$\frac{\partial l(\theta)}{\partial \theta} = -\frac{n}{2\theta} + \frac{1}{2\theta^2} \sum_{i=1}^n X_i^2 - \frac{n}{2}$$

Derivando respecto a θ obtenemos

$$\frac{\partial^2 l(\theta)}{\partial \theta^2} = \frac{n}{2\theta^2} - \frac{1}{\theta^3} \sum_{i=1}^n X_i^2$$

Luego

$$\begin{aligned} -\mathbb{E}\left(\frac{\partial^2 l(\theta)}{\partial \theta^2}\right) &= -\frac{n}{2\theta^2} + \frac{1}{\theta^3} \sum_{i=1}^n \mathbb{E}(X_i^2) \\ &= -\frac{n}{2\theta^2} + \frac{n(\theta + \theta^2)}{\theta^3} \\ &= \frac{n(\theta + 1/2)}{\theta^2} \end{aligned}$$

Entonces

$$\text{Var}(\hat{\theta}) \geq \frac{1}{-\mathbb{E}\left(\frac{\partial^2 l(\theta)}{\partial \theta^2}\right)} = \frac{\theta^2}{n(\theta + 1/2)} = \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_{MLE})$$

Ejercicio 4: Sesgo de un estimador

Un estimador $\hat{\theta}$ de un parámetro θ tiene distribución normal. Se sabe además que $\text{ECM}(\hat{\theta}) = 8$ y $P(\hat{\theta} \leq \theta) = 0,8413$. Hallar el sesgo de $\hat{\theta}$.

Sugerencia: Usar

$$X \sim \mathcal{N}(0, 1) \Rightarrow \mathbb{P}(X \leq 1) = 0,8413$$

Ejercicio 5

Comparación de estimadores. Ana y Beto saben que el delivery llega en un tiempo uniforme en el intervalo $[0, a]$, en donde 0 es el momento en el que hacen el pedido, y a es un valor desconocido. Se deciden a estimar a , y para esto disponen de un muestreo aleatorio X_1, \dots, X_n . Proponen los siguientes estimadores:

$$A_n = \max\{X_1, \dots, X_n\} \quad \text{y} \quad B_n = 2X_n.$$

- 1 Calcular el sesgo y el error cuadrático medio de B_n . Determinar si B_n es consistente.
- 2 Demostrar que la densidad de A_n es

$$p_A(x) = \begin{cases} \frac{nx^{n-1}}{a^n} & \text{si } 0 \leq x \leq a, \\ 0 & \text{si no.} \end{cases}$$

- 3 Calcular el sesgo y el error cuadrático medio de A_n . ¿Es asintóticamente insesgado?

Sugerencias:

- 1 Para determinar si B_n es consistente, es suficiente probar que $EMC(B_n) \rightarrow 0$ con $n \rightarrow \infty$
- 2 Notar que

$$F_{A_n}(x) = \mathbb{P}(\max\{X_1, \dots, X_n\} \leq x) = \mathbb{P}(X_1 \leq x, \dots, X_n \leq x)$$

y que las X_i son independientes y $X_i \sim U[0, a]$.

- 3 Usar la descomposición sesgo varianza del $EMC(A_n)$

Ejercicio 6

Estimador de mínima varianza. Se considera la condición (C):

$$\frac{\partial \ell(\theta, x)}{\partial \theta} = I(\theta)(T(x) - \theta).$$

- 1 Probar que si un estimador $T(x)$ satisface la condición (C), entonces $I(\theta)$ es la información de Fisher de θ .
- 2 Probar que si $\hat{\theta}_{\text{MLE}}$ es el estimador de máxima verosimilitud de θ y $T(x)$ cumple con la condición (C), entonces $T(x) = \hat{\theta}_{\text{MLE}}$.

Sugerencia: Para la parte 2, recordar que el estimador de máxima verosimilitud maximiza la función de log verosimilitud (derivada de la log verosimilitud es 0)

Ejercicio 7: El método delta

Sea X una variable aleatoria con la siguiente densidad de probabilidad:


$$p(x; a) = (a + 1)x^a \quad \text{si } 0 < x < 1; \quad 0 \text{ en otro caso.}$$

Sea X_1, \dots, X_n un muestreo aleatorio de X .


- 1 Hallar el estimador de máxima verosimilitud \hat{a} de a .
- 2 Hallar la densidad de $Y = -\ln(X)$ y calcular $\mu = \mathbb{E}(Y)$ en función de a .
- 3 Verificar que $\hat{a} = g(Y_n)$, con $g(y) = \frac{1}{y} - 1$, y probar que \hat{a} es consistente.
- 4 Usando el desarrollo $\hat{a} - a = g(Y_n) - g(\mu) \approx g'(\mu)(Y_n - \mu)$ para n grande:
 - 1 Probar que \hat{a} es asintóticamente insesgado.
 - 2 Hallar la varianza asintótica de \hat{a} .
 - 3 ¿Es \hat{a} asintóticamente normal?
- 5 Se dispone de la siguiente muestra de X :
0.56, 0.82, 0.71, 0.87, 0.33, 0.36, 0.93, 0.94, 0.89, 0.42.
Hallar un intervalo de confianza asintótico para a al nivel 0.9.

Ejercicio 7


Parte 5



Confianza: 90%
Punto de corte: 1.64



Confianza: 96%
Punto de corte: 1.96



Confianza: 99%
Punto de corte: 2.57

$$\mathbb{P}(a_1 \leq a \leq a_2) = 0,9$$

$$a_1 = \hat{a} - z_{\alpha/2} \sqrt{\text{Var}(\hat{a})}$$

$$a_2 = \hat{a} + z_{\alpha/2} \sqrt{\text{Var}(\hat{a})}$$

Figura: <https://fernandoblancopsy.com>

- En este caso $z_{\alpha/2} = 1,64$
- \hat{a} , $\text{Var}(\hat{a})$ se calculan a partir de los datos.
- $\text{Var}(\hat{a})$ es la varianza asintótica (porque nos pide el intervalo de confianza asintótico).

Ejercicio 8: Transformación de estimadores eficientes

Supongamos que $\hat{\theta}$ es un estimador eficiente de θ (insesgado y alcanza la cota de Cramér-Rao).

- 1 Consideramos la transformación $f(\theta) = a\theta + b = \alpha$. Probar que $\hat{f}(\theta) = a\hat{\theta} + b$ es un estimador eficiente de $\alpha = f(\theta)$.
- 2 Si $f(\theta) = \theta^2$, muestre que $\hat{f}(\theta) = \hat{\theta}^2$ deja de ser eficiente para θ^2 pero sí lo es asintóticamente. Se sugiere considerar $\hat{\theta} = \bar{X}$ estimador de μ con una muestra X_1, \dots, X_n iid de $N(\mu, \sigma^2)$.

Sugerencias:

- 1 En la parte 1 utilizar que la cota de CR para $\alpha = f(\theta)$ es

$$\text{Var}(\alpha) \geq \frac{\left(\frac{\partial f}{\partial \theta}\right)^2}{\mathcal{I}(\theta)}$$

- 2 En la parte 2 utilizar que si $Z \sim \mathcal{N}(\mu, \sigma^2)$ entonces

$$\text{Var}(Z^2) = 4\mu^2\sigma^2 + 2\sigma^2$$

Ejercicio 9: Divergencia de Kullback-Leibler

- 1 Probar que la divergencia de Kullback-Leibler $D(p\|q) \geq 0$ y que $D(p\|q) = 0 \iff p(x) = q(x)$ para todo x .
- 2 Calcular $D(f_1\|f_2)$ en los siguientes casos:
 - 1 $f_1 = \mathcal{N}(2, \sigma^2)$ y $f_2 = \mathcal{N}(4, \sigma^2)$.
 - 2 $f_1 = \mathcal{N}(\mu_1, \sigma_1^2)$ y $f_2 = \mathcal{N}(\mu_2, \sigma_2^2)$.

Sugerencias:

- 1 En la parte 1, demostrar que $-D(p\|q) \leq 0$ usando

$$\log(x) \leq x - 1$$

También se puede hacer usando la desigualdad de Jensen.

- 2 Para demostrar $D(p\|q) = 0 \iff p(x) = q(x)$ para todo x , usar que $\log(x)$ es estrictamente cóncava, y recordar la desigualdad de Jensen para funciones estrictamente cóncavas (la usamos en el ejercicio 3)
- 3 En la parte 2, hacer cuentas!

Ejercicio 10: Información de Fisher

Calcular la información de Fisher en cada uno de los casos siguientes:

- 1 Si $X \sim \text{Ber}(p)$.
- 2 Si $X \sim \exp(\lambda)$.
- 3 Si $X \sim \mathcal{N}(\mu, 4)$.

Recordar que la información de Fisher se define como

$$\mathcal{I}(\theta) = -\mathbb{E} \left[\frac{\partial^2 \log \mathcal{L}(\theta)}{\partial \theta^2} \right]$$

1) $X \sim \text{Ber}(p)$

$$\mathcal{L}(p) = f_p(x) = p^x(1-p)^{1-x} \quad x = 0, 1$$

La función de log verosimilitud es

$$l(p) = \log \mathcal{L}(p) = x \log(p) + (1-x) \log(1-p)$$

Luego derivamos dos veces la log verosimilitud

$$\frac{\partial l(p)}{\partial p} = \frac{x}{p} - \frac{1-x}{1-p}$$

$$\frac{\partial^2 l(p)}{\partial p^2} = -\frac{x}{p^2} - \frac{1-x}{(1-p)^2}$$

y calculamos la esperanza (respecto a la distribución de X)

$$\begin{aligned}\mathcal{I}(p) &= -\mathbb{E} \left[\frac{\partial^2 \log \mathcal{L}(p)}{\partial p^2} \right] = -\mathbb{E} \left[-\frac{X}{p^2} - \frac{1-X}{(1-p)^2} \right] \\ &= \frac{\mathbb{E}(X)}{p^2} + \frac{1-\mathbb{E}(X)}{(1-p)^2} \\ &= \frac{p}{p^2} + \frac{1-p}{(1-p)^2} \\ &= \frac{1}{p(1-p)}\end{aligned}$$

Ejercicio 11: Cramér-Rao Generalizado

Si $\hat{\theta}_n$ es un estimador de θ con $\mathbb{E}_{X \sim f_\theta}(\hat{\theta}_n) = \tau(\theta)$, entonces

$$\text{Var}(\hat{\theta}_n) \geq \frac{|\tau'(\theta)|^2}{n\mathcal{I}_1(\theta)}$$

Sugerencia: Ver prueba realizada en el teórico (Tema 3, diapositiva 39)

Para estimadores insesgados se utiliza que

$$\text{Cov}\left(\hat{\theta}_n, \frac{\partial l(\theta)}{\partial \theta}\right) = 1$$

En este caso la cuenta va a ser la misma, pero

$$\text{Cov}\left(\hat{\theta}_n, \frac{\partial l(\theta)}{\partial \theta}\right) = \tau'(\theta)$$

(demostrarlo)

Viernes 13/9:

- Regresión lineal simple.