

Algo más sobre Estadística

Pablo L. De Nápoli

Departamento de Matemática
Facultad de Ciencias Exactas y Naturales
Universidad de Buenos Aires

Probabilidades y Estadística para Matemática
Segundo cuatrimestre de 2021

Parte I

Estimadores de máxima verosimilitud

Introducción

En la clase anterior, vimos que uno de los problemas centrales de la estadística es la **estimación de parámetros** de una distribución.

Supongamos que tenemos una población y queremos medir una cierta variable aleatoria, cuya distribución F no conocemos, pero sabemos o suponemos que $F \in \mathcal{F}$, una cierta familia de distribuciones.

Para estimar un parámetro $\theta = \theta(F)$, tomamos una muestra aleatoria de tamaño n de nuestra población. Esto nos dará variables

$$X_1, X_2, \dots, X_n$$

todas con distribución F e independientes. Entonces queremos estimar θ mediante un **estimador**

$$\hat{\theta}(X_1, X_2, \dots, X_n)$$

En esta clase, veremos un método general para obtener estimadores con buenas propiedades.

Notación vectorial

En muchos ejemplos la distribución estará caracterizada por un número finito k de parámetros, que podemos pensar como componentes de un vector

$$\theta = (\theta_1, \theta_2, \dots, \theta_k) \in \mathbb{R}^k$$

que se mueve en una cierta región $A \subset \mathbb{R}^k$ de parámetros admisibles.

Por ejemplo, podemos pensar en la familia de distribuciones normales:

$$\mathcal{F} = \{N(\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma > 0\}$$

En este caso $\theta = (\mu, \sigma) \in A$, donde

$$A = \{(\mu, \sigma) : \mu \in \mathbb{R}, \sigma > 0\}$$

En general, podemos escribir

$$\mathcal{F} = \{F_\theta : \theta \in A\}$$

Caso discreto

Comenzemos considerando el caso discreto. En este caso la distribución F_θ vendrá dada por las probabilidades puntuales, que dependerán del vector de parámetros θ :

$$p_\theta(x) = P\{X_i = x\} \quad (\text{las mismas para todo})$$

(que serán cero salvo para numerables valores de x)

Por ejemplo, supongamos que tenemos una urna con un cierto número de bolitas blancas B y otro tanto de rojas R , y que extraemos n bolitas con reposición pero no conocemos cuántas bolitas de cada color hay. Definimos las variables aleatorias de Bernoulli

$$X_i = \begin{cases} 1 & \text{si sale roja} \\ 0 & \text{si sale blanca} \end{cases}$$

Entonces $X_i \sim \text{Be}(\theta)$ donde $\theta = \frac{R}{B+R} \in [0, 1] = A$. Aquí los posibles valores de las X_i son 0 y 1, y sus probabilidades

$$p_\theta(1) = \theta, \quad p_\theta(0) = 1 - \theta$$

Verosimilitud en el caso discreto

Ahora nos preguntamos: si el parámetro θ tuviera un cierto valor, ¿cuál sería la probabilidad de observar ciertos valores x_1, x_2, \dots, x_n ? Esto vendrá dado por la **función de verosimilitud**

$$\begin{aligned}\mathcal{L}(\theta) &= \mathcal{L}(x_1, x_2, \dots, x_n; \theta) := P_\theta\{X_1 = x_1, X_2 = x_2, \dots, X_n = x_n\} \\ &= \prod_{i=1}^n P_\theta\{X = x_i\} \quad \text{por independencia} \\ &= \prod_{i=1}^n p_\theta(x_i)\end{aligned}$$

Aquí usamos la notación P_θ para indicar que las probabilidades indicadas dependen del parámetro θ .

Cuando trabajamos con variables continuas, la distribución F_θ estará caracterizada por una densidad de probabilidad f_θ . entonces definimos la función de **función de verosimilitud** como la densidad conjunta del vector aleatorio (X_1, X_2, \dots, X_n) correspondiente a un determinado valor del parámetro θ , que de nuevo por la independencia de la muestra será:

$$\mathcal{L}(\theta) = \mathcal{L}(x_1, x_2, \dots, x_n; \theta) := \prod_{i=1}^n f_\theta(x_i)$$

Caso discreto (3)

Para cada muestra particular (x_1, \dots, x_n) , la estimación de máxima verosimilitud de θ es el valor $\hat{\theta}_{VM}$ que maximiza la verosimilitud. Es decir:

$$\mathcal{L}(x_1, x_2, x_n; \hat{\theta}_{MV}) = \max_{\theta \in A} \mathcal{L}(x_1, \dots, x_n; \theta)$$

El estimador de máxima verosimilitud, $\hat{\theta}_{VM}(X_1, X_2, \dots, X_n)$, es aquél que evaluado en cada muestra particular nos da la estimación de máxima verosimilitud

$$\hat{\theta}_{MV}(x_1, x_2, \dots, x_n)$$

Como \mathcal{L} es un producto, conviene maximizar $\ell(s) = \log \mathcal{L}(\theta)$.

Continuación del ejemplo en el caso discreto

En el ejemplo que vimos antes de la distribución $\text{Be}(\theta)$:

$$\mathcal{L}(\theta) = \theta^s (1 - \theta)^{n-s}$$

donde

$$s = x_1 + x_2 + \dots + x_n$$

Luego:

$$\ell(\theta) = \log \mathcal{L}(\theta) = s \log \theta + (n - s) \log(1 - \theta)$$

$$\ell'(\theta) = s \cdot \frac{1}{\theta} - (n - s) \cdot \frac{1}{1 - \theta}$$

El máximo se va a alcanzar cuando $\ell'(s) = 0$, o sea:

$$\frac{s}{\theta} = \frac{n - s}{1 - \theta} \Leftrightarrow \frac{1 - \theta}{\theta} = \frac{n - s}{s} \Leftrightarrow \frac{1}{\theta} - s = \frac{n}{s} - 1 \Leftrightarrow \theta = \frac{s}{n}$$

Así que en este caso el mejor

$$\hat{\theta}_{MV} = \bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}$$

Estimación de los parámetros de la distribución normal

Volvamos al ejemplo de la familia de las distribuciones normales. Son distribuciones continuas con la densidad:

$$f_{\theta}(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/(2\sigma^2)} \quad \theta = (\mu, \sigma)$$

Entonces:

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

luego

$$\ell(\theta) = \log \mathcal{L}(\theta) = -n \log \sigma - \frac{1}{2} \log(2\pi) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}$$

Estimación de los parámetros de la distribución normal (2)

Como ahora tenemos dos parámetros, para encontrar el máximo vemos donde se anulan simultáneamente ambas derivadas parciales:

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

$$\frac{\partial \ell}{\partial \sigma}(\theta) = -\frac{n}{\sigma} + \sum_{i=1}^n \frac{(x_i - \mu)^2}{\sigma^3} = 0 \Rightarrow \sigma = \left(\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \right)^{1/2}$$

O sea que los **estimadores de máxima verosimilitud** para los parámetros de la distribución normal son:

$$\hat{\mu} = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\hat{\sigma} = \left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X}_n)^2 \right)^{1/2}$$