

1. MÉTODO DE MOMENTOS

Elijamos como estimaciones aquellos valores de los parámetros que sean soluciones de la ecuación $\mu'_k = m'_k$ para $k = 1, 2, \dots, t$, donde t es el número de parámetros a estimar.

Como sabemos, $\mu'_k = E[Y^k]$, con μ'_k representando la k -ésima derivada de la función generadora de momentos evaluada en cero. El k -ésimo momento muestral correspondiente es el promedio

$$m'_k = \frac{1}{n} \sum_{i=1}^n Y_i^k.$$

Por lo tanto, el método de los momentos tiene la idea de que los momentos muestrales deben proveer estimaciones acertadas acerca de los momentos poblacionales.

EJEMPLO. Una urna contiene θ bolas negras y $N - \theta$ bolas blancas. Se selecciona una muestra de n bolas sin reemplazo. Sea Y el número de bolas negras en la muestra. Demuestre que $\frac{N\bar{Y}}{n}$ es el estimador para θ .

SOLUCIÓN.

Este experimento sigue una distribución de tipo hipergeométrica, con parámetros N , n y θ . Como sabemos \bar{Y} es el mejor estimador para $E[Y]$, que por ser hipergeométrica es

$$E[Y] = \frac{n\theta}{N} = \bar{Y} \Rightarrow \hat{\theta} = \frac{N}{n}\bar{Y}.$$

EJEMPLO. Si Y_1, Y_2, \dots, Y_n denota una muestra aleatoria de una distribución normal con media μ y varianza σ^2 , encuentre los estimadores de μ y σ^2 por el método de momentos.

SOLUCIÓN.

Como sabemos $E[Y] = \mu = \bar{Y}$ y $E[Y^2] = \sigma^2 + \mu^2 = \frac{1}{n} \sum_{i=1}^n Y_i^2$, despejando tenemos

$$\sigma^2 + \mu^2 = \frac{1}{n} \sum_{i=1}^n Y_i^2 \Rightarrow \sigma^2 + \bar{Y}^2 = \frac{1}{n} \sum_{i=1}^n Y_i^2 \Rightarrow \sigma^2 = \frac{1}{n} \sum_{i=1}^n Y_i^2 - \bar{Y}^2$$

$$\Rightarrow \sigma^2 = \frac{\sum_{i=1}^n Y_i^2 - n\bar{Y}^2}{n} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}.$$

$$\text{Por lo tanto } \hat{\mu} = \bar{Y} \text{ y } \hat{\sigma}^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}.$$

Es importante notar que $\hat{\mu}$ es insesgado y $\hat{\sigma}^2$ no lo es, sin embargo este último se puede modificar fácilmente para que sea insesgado.

2. MÉTODO DE MÁXIMA VEROSIMILITUD

Suponga que la función de verosimilitud depende de k parámetros $\theta_1, \theta_2, \dots, \theta_k$. Elija como estimaciones aquellos valores de los parámetros que maximizan la verosimilitud $L(y_1, y_2, \dots, y_n | \theta_1, \theta_2, \dots, \theta_k)$.

EJEMPLO. Suponga que Y_1, Y_2, \dots, Y_n denota una muestra aleatoria de la distribución de Poisson con media λ .

- Encuentre el estimador de máxima verosimilitud $\hat{\lambda}$ para λ .
- Encuentre el valor esperado y la varianza de $\hat{\lambda}$.
- Demuestre que el estimador del inciso a) es consistente para λ .

SOLUCIÓN.

La verosimilitud en este caso es

$$\begin{aligned} L(\lambda) &= p(y_1, \dots, y_n | \lambda) = p(y_1 | \lambda) \dots p(y_n | \lambda) = \frac{\lambda^{y_1} e^{-\lambda}}{y_1!} \dots \frac{\lambda^{y_n} e^{-\lambda}}{y_n!} \\ &= \frac{\lambda^{\sum_{i=1}^n y_i} e^{-n\lambda}}{\prod_{i=1}^n y_i!}. \end{aligned}$$

Para facilitar los cálculos trabajaremos con $\ln[L(\lambda)]$, y nos queda

$$\ln[L(\lambda)] = \ln(\lambda) \sum_{i=1}^n y_i - n\lambda - \sum_{i=1}^n \ln(y_i!)$$

Derivando nos queda:

$$\frac{d \ln[L(\lambda)]}{d\lambda} = \frac{1}{\lambda} \sum_{i=1}^n y_i - n = 0 \Rightarrow \hat{\lambda} = \bar{Y}.$$

Ahora conseguimos su valor esperado y su varianza

$$E[\hat{\lambda}] = \frac{1}{n} \sum_{i=1}^n E[Y_i] = \lambda.$$

$$V(\hat{\lambda}) = \frac{1}{n^2} \sum_{i=1}^n V(Y_i) = \frac{\lambda}{n}.$$

Para demostrar que el estimador es consistente debemos ver que $\lim_{n \rightarrow \infty} V(\hat{\lambda}) = 0$.

$$\lim_{n \rightarrow \infty} V(\hat{\lambda}) = \lim_{n \rightarrow \infty} \frac{\lambda}{n} = 0.$$

Por lo tanto es consistente.

EJEMPLO. Sea Y_1, Y_2, \dots, Y_n una muestra de una distribución normal con media μ y varianza σ^2 . Obtenga los estimadores de máxima verosimilitud de μ y σ^2 .

SOLUCIÓN.

$$\begin{aligned} L(\mu, \sigma^2) &= f(y_1, y_2, \dots, y_n | \mu, \sigma^2) = f(y_1 | \mu, \sigma^2) \dots f(y_n | \mu, \sigma^2) \\ &= \left\{ \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_1 - \mu)^2}{2\sigma^2}} \right\} \dots \left\{ \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_n - \mu)^2}{2\sigma^2}} \right\} \\ &= \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu)^2}. \end{aligned}$$

Para facilitar el cálculo trabajaremos con $\ln[L(\mu, \sigma^2)]$. Luego

$$\ln[L(\mu, \sigma^2)] = -\frac{n}{2} \ln(\sigma^2) - \frac{n}{2} \ln(2\pi) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu)^2$$

Para conseguir los estimadores de máxima verosimilitud, queremos maximizar $\ln[L(\mu, \sigma^2)]$ respecto a los parámetros desconocidos, en este caso

$$\frac{\partial \ln[L(\mu, \sigma^2)]}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (y_i - \mu).$$

$$\frac{\partial \ln[L(\mu, \sigma^2)]}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (y_i - \mu)^2.$$

Igualando a cero nos queda

$$\frac{1}{\sigma^2} \sum_{i=1}^n (y_i - \hat{\mu}) = 0 \Rightarrow \sum_{i=1}^n y_i - n\hat{\mu} = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n y_i = \bar{Y}.$$

y sustituyendo

$$-\frac{n}{2\hat{\sigma}^2} + \frac{1}{2\hat{\sigma}^4} \sum_{i=1}^n (y_i - \bar{Y})^2 = 0 \Rightarrow \hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \bar{Y})^2}{n}.$$

EJEMPLO. Sea Y_1, Y_2, \dots, Y_n una muestra aleatoria de observaciones de una distribución uniforme con función de densidad de probabilidad $f(y_i|\theta) = 1/\theta$, para $0 \leq y_i \leq \theta$ e $i = 1, \dots, n$. Obtenga el estimador de máxima verosimilitud de θ .

SOLUCIÓN.

La verosimilitud es

$$L(\theta) = f(y_1, y_2, \dots, y_n|\theta) = f(y_1|\theta) \dots f(y_n|\theta) = \frac{1}{\theta} \dots \frac{1}{\theta} = \frac{1}{\theta^n}.$$

Por otro lado

$$\frac{dL(\theta)}{d\theta} = -\frac{n}{\theta^{n-1}}$$

Y claramente no existe ningún valor de θ tal que esa derivada se anule. Sin embargo mientras más pequeño es θ , más grande es el valor de la verosimilitud, por lo tanto estamos interesados en el valor más pequeño de θ , el cual se consigue con el valor más grande de las observaciones. Luego tomaremos $\hat{\theta} = Y_{(n)} = \max(Y_1, \dots, Y_n)$. Aunque el máximo no es insesgado, se puede adaptar para que una función de él lo sea.