

Tema 4: Inferencia Estadística I. Estimación Puntual.

Estadística. Grado en Ciencias del Mar



Concepto de inferencia estadística

La **inferencia estadística** es el proceso mediante el cual se extienden o generalizan a una **población** las conclusiones o resultados obtenidos a partir de la información proporcionada por una **muestra** de la misma.

Objetivos de la inferencia estadística

1. **Estimación de parámetros:** obtener valores aproximados de los parámetros que caracterizan el comportamiento de las variables de interés en la población.
2. **Contraste de hipótesis:** decidir sobre la validez o no de hipótesis relativas a alguna característica de la población.

Población y muestra

- En la práctica, la inferencia se realiza sobre **variables** (peso, talla, temperatura, concentración, velocidad, ...) que se miden en los elementos que componen la población.
- Por tanto cuando hablamos de caracterizar una población, en realidad nos referimos a caracterizar las variables de interés; y caracterizar una variable significa conocer en qué forma se reparten o distribuyen sus valores; en otras palabras, *conocer su distribución de probabilidad*.
- Para ello utilizamos la información que aporta una *muestra aleatoria*, definida como un conjunto de observaciones *independientes* X_1, X_2, \dots, X_n de la variable de interés.

¿De verdad una muestra informa sobre una población?

- **Función de distribución empírica:** Dada una muestra aleatoria X_1, \dots, X_n , se define la función de distribución empírica:

$\hat{F}_n(x)$ = proporción de valores menores o iguales que x en la muestra

- **Teorema de Glivenko-Cantelli:** Sea X_1, \dots, X_n una muestra aleatoria de una variable aleatoria X con función de distribución $F(x)$, y sea $\hat{F}_n(x)$ la función de distribución empírica de la muestra. Entonces para cualquier valor x se verifica, a medida que $n \rightarrow \infty$:

$$E \left[\left(\hat{F}_n(x) - F(x) \right)^2 \right] \rightarrow 0$$

- Por tanto a medida que aumenta el tamaño de la muestra, su distribución empírica se va asemejando cada vez más a la distribución de la variable de interés \Rightarrow Efectivamente la muestra *informa* sobre la población.

Inferencia estadística paramétrica

- Cuando la variable X sobre la que deseamos realizar inferencias tiene una función de distribución caracterizada por un vector de parámetros $\theta = (\theta_1, \dots, \theta_k)$, nuestro primer problema suele ser determinar un valor aproximado de θ .
- El proceso por el cuál se obtiene dicho valor aproximado se llama *estimación*. Un *estimador puntual* es una función de la muestra que produce valores próximos al parámetro que se desea conocer.
- ¿Cómo se construye un estimador?
 - Método de analogía
 - Método de los momentos
 - Método de máxima verosimilitud

¿Cómo se construye un estimador?

- **Método de analogía:** El parámetro poblacional se estima mediante su análogo en la muestra: la media poblacional se estima mediante la media muestral, la proporción en la población mediante la proporción en la muestra, ...
- **Método de los momentos:** El parámetro se expresa como función de los momentos (media, varianza, ... de la población) y se estima mediante la misma función evaluada a partir de los momentos análogos (media, varianza, ...) de la muestra.
- **Ejemplo:** en la distribución *Gamma* (α, β) se tiene que $\mu = \frac{\alpha}{\beta}$ y $\sigma^2 = \frac{\alpha}{\beta^2}$. Por tanto:

$$\beta = \frac{\mu}{\sigma^2} \Rightarrow \hat{\beta} = \frac{\bar{x}}{s^2}$$

$$\alpha = \mu\beta \Rightarrow \hat{\alpha} = \bar{x} \frac{\bar{x}}{s^2} = \frac{\bar{x}^2}{s^2}$$

¿Cómo se construye un estimador?

- **Método de analogía:** El parámetro poblacional se estima mediante su análogo en la muestra: la media poblacional se estima mediante la media muestral, la proporción en la población mediante la proporción en la muestra, ...
- **Método de los momentos:** El parámetro se expresa como función de los momentos (media, varianza, ... de la población) y se estima mediante la misma función evaluada a partir de los momentos análogos (media, varianza, ...) de la muestra.
- **Método de máxima verosimilitud:** El parámetro se estima mediante aquel valor que maximiza *a priori* la probabilidad de observar la muestra que se ha observado.

Los distintos procedimientos pueden dar lugar a distintos estimadores para un mismo parámetro

Ejemplo



El abdomen del cangrejo de mar común (*Carcinus maenas*) está integrado por siete segmentos dispuestos paralelamente. En los machos se suelen apreciar fusiones entre los segmentos 3, 4 y 5. Se considera la variable aleatoria X ="Número de segmentos fusionados". Esta variable puede tomar los valores 0 (ninguna fusión), 1 (se fusionan los segmentos 3 y 4, ó el 4 y 5), y 2 (se fusionan los tres segmentos entre sí). A través de diversas consideraciones sobre la genética de esta población de cangrejos, se llega a la conclusión de que las probabilidades asociadas a esta variable son de la forma:

$$P(X = 0) = \frac{a - 1}{a(a + 1)} \quad P(X = 1) = \frac{a - 1}{a + 1} \quad P(X = 2) = \frac{1}{a}, \quad a > 1$$

En una muestra de 100 cangrejos se han encontrado 18 sin fusiones, 43 que presentan una fusión y 39 que presentan dos fusiones. Utilizar esta información para obtener un valor aproximado de a :

- Por analogía
- Por el método de los momentos.
- Por el método de máxima verosimilitud.

Método de analogía

El **método de analogía** consiste en expresar el parámetro como función de alguna operación numérica realizada con valores de la población, y calcular el estimador analógico como el resultado de aplicar *esa misma función* a los valores medidos en la muestra.

Ejemplo

En el ejemplo de los cangrejos se tiene que:

$$P(X = 2) = \frac{1}{a} \rightarrow a = \frac{1}{P(X = 2)}$$

Por tanto, si p_2 es la **proporción de cangrejos con dos fusiones en la muestra**, el estimador analógico de a es:

$$\hat{a} = \frac{1}{p_2}$$

Método de analogía

En nuestra muestra de 100 cangrejos hay 18 sin fusiones, 43 con una fusión y 39 con dos fusiones. Por tanto:

$$p_0 = \frac{18}{100} = 0.18 \quad p_1 = \frac{43}{100} = 0.43 \quad p_2 = \frac{39}{100} = 0.39$$

y el valor estimado de a es:

$$\hat{a} = \frac{1}{0.39} = 2.5641$$

Nótese que un **estimador analógico** es una **función de la muestra**. Una vez que la función se aplica y se obtiene un valor, éste es el *valor estimado del parámetro*.

Por tanto, **distintas muestras** darán lugar a **distintos valores estimados**.

Método de analogía

Nótese que también podíamos haber argumentado que como:

$$\begin{aligned}P(X = 1) &= \frac{a - 1}{a + 1} \Rightarrow (a + 1)P(X = 1) = a - 1 \Rightarrow \\ &\Rightarrow P(X = 1) + 1 = a - aP(X = 1)\end{aligned}$$

de donde:

$$a = \frac{1 + P(X = 1)}{1 - P(X = 1)}$$

y por tanto **otro** estimador analógico **del mismo** parámetro a es:

$$\hat{a} = \frac{1 + p_1}{1 - p_1}$$

que en nuestro caso vale:

$$\hat{a} = \frac{1 + 0.43}{1 - 0.43} = \frac{1.43}{0.57} = 2.5088$$

Método de analogía

También podíamos haber despejado a de:

$$\begin{aligned}P(X = 0) &= \frac{a - 1}{a(a + 1)} \Rightarrow (a^2 + a)P(X = 0) = a - 1 \Rightarrow \\&\Rightarrow P(X = 0)a^2 - (1 - P(X = 0))a + 1 = 0 \Rightarrow \\a &= \frac{(1 - P(X = 0)) \pm \sqrt{(1 - P(X = 0))^2 - 4P(X = 0)}}{2P(X = 0)}\end{aligned}$$

El estimador analógico sería entonces:

$$\hat{a} = \frac{(1 - p_0) \pm \sqrt{(1 - p_0)^2 - 4p_0}}{2p_0}$$

Esta ecuación no siempre tiene solución; y cuando la tiene produce dos valores de $\hat{a} > 1$

Método de analogía

En nuestro ejemplo, como $p_0 = 0.18$ tenemos:

$$\hat{a} = \frac{0.82 \pm \sqrt{0.82^2 - 4 \cdot 0.18}}{2 \cdot 0.18}$$

que no tiene solución porque el término dentro de la raíz es negativo.

Método de los momentos

- Se define el **momento** de orden k de una variable aleatoria X como:

$$\mu_k = E [X^k]$$

- Asimismo se define el **momento muestral** de orden k de una muestra X_1, X_2, \dots, X_n como:

$$m_k = \frac{1}{n} \sum_{i=1}^n X_i^k$$

El **método de los momentos** consiste en expresar el parámetro como función de uno o varios momentos μ_k de la variable aleatoria y estimarlo como la misma función evaluada sobre los momentos muestrales correspondientes:

$$\theta = f(\mu_1, \mu_2, \dots, \mu_r) \Rightarrow \hat{\theta} = f(m_1, m_2, \dots, m_r)$$

Método de los momentos

El momento de primer orden es la esperanza, que en nuestro ejemplo es:

$$\begin{aligned}\mu &= E[X] = 0 \cdot P(X = 0) + 1 \cdot P(X = 1) + 2 \cdot P(X = 2) = \\ &= \frac{a-1}{a+1} + 2 \frac{1}{a} = \frac{a(a-1) + 2(a+1)}{a(a+1)} = \frac{a^2 + a + 2}{a^2 + a}\end{aligned}$$

Por tanto:

$$a^2 + a + 2 = \mu (a^2 + a) \Rightarrow (\mu - 1) a^2 + (\mu - 1) a - 2 = 0$$

y de aquí podemos despejar a :

$$a = \frac{-(\mu - 1) \pm \sqrt{(\mu - 1)^2 + 8(\mu - 1)}}{2(\mu - 1)} = \frac{-(\mu - 1) \pm \sqrt{(\mu - 1)(\mu + 7)}}{2(\mu - 1)}$$

Para que $a > 1$ tomamos la raíz positiva:

$$a = \frac{-(\mu - 1) + \sqrt{(\mu - 1)(\mu + 7)}}{2(\mu - 1)}$$

(nótese que $\mu = \frac{a^2+a+2}{a^2+a} > 1$)

Método de los momentos

El estimador por el método de los momentos de a se obtiene sustituyendo el momento μ (la esperanza) por su homólogo muestral \bar{x} (la media muestral):

$$\hat{a} = \frac{-(\bar{x} - 1) + \sqrt{(\bar{x} - 1)(\bar{x} + 7)}}{2(\bar{x} - 1)}$$

En nuestro ejemplo, el número medio de fusiones en el abdomen de la muestra de cangrejos es:

$$\bar{x} = \frac{0 \cdot 18 + 1 \cdot 43 + 2 \cdot 39}{100} = \frac{121}{100} = 1.21$$

y por tanto:

$$\hat{a} = \frac{-0.21 + \sqrt{0.21 \cdot 8.21}}{2 \cdot 0.21} = 2.6262$$

Nótese que aunque $\mu > 1$, en alguna muestra podría ocurrir que $\bar{x} < 1$ y en tal caso el estimador anterior no podría calcularse.

Método de máxima verosimilitud

El **estimador de máxima verosimilitud** se obtiene como aquel valor del parámetro que maximiza *a priori* la probabilidad de observar la muestra que se ha observado *de facto*.

En nuestro ejemplo, si se toma una muestra aleatoria de n cangrejos, a priori la probabilidad de que n_0 no tengan fusiones, n_1 tengan una fusión y n_2 tengan dos fusiones sería:

$$L(a) = \frac{n!}{n_0!n_1!n_2!} \pi_0^{n_0} \pi_1^{n_1} \pi_2^{n_2} = \frac{n!}{n_0!n_1!n_2!} \left(\frac{a-1}{a(a+1)} \right)^{n_0} \left(\frac{a-1}{a+1} \right)^{n_1} \left(\frac{1}{a} \right)^{n_2}$$

Esta función se denomina **función de verosimilitud**.

Método de máxima verosimilitud

Para obtener el valor de a es el valor que maximiza esta probabilidad podríamos derivar respecto de a e igualar a 0. ¡Complicado!

Si tenemos en cuenta que el lugar donde una función alcanza el máximo es el mismo que donde lo alcanza su logaritmo, **maximizar la función anterior es equivalente a maximizar su logaritmo.**

El logaritmo de la verosimilitud en nuestro ejemplo es:

$$\begin{aligned} l(a) &= \log \left(\frac{n!}{n_0!n_1!n_2!} \left(\frac{a-1}{a(a+1)} \right)^{n_0} \left(\frac{a-1}{a+1} \right)^{n_1} \left(\frac{1}{a} \right)^{n_2} \right) = \\ &= \log \left(\frac{n!}{n_0!n_1!n_2!} \right) + n_0 [\log(a-1) - \log(a) - \log(a+1)] + \\ &\quad + n_1 [\log(a-1) - \log(a+1)] - n_2 \log(a) \end{aligned}$$

Esta función se denomina **log-verosimilitud** y su derivada es normalmente sencilla de calcular.

Método de máxima verosimilitud

Simplificando:

$$l(a) = \log\left(\frac{n!}{n_0!n_1!n_2!}\right) + (n_0 + n_1) \log(a - 1) - \\ - (n_0 + n_2) \log(a) - (n_0 + n_1) \log(a + 1)$$

Ahora es fácil derivar, igualar a cero y despejar:

$$l'(a) = \frac{n_0 + n_1}{a - 1} - \frac{n_0 + n_2}{a} - \frac{n_0 + n_1}{a + 1} = 0$$

$$(n_0 + n_1)(a^2 + a) - (n_0 + n_2)(a^2 - 1) - (n_0 + n_1)(a^2 - a) = 0$$

$$- (n_0 + n_2)a^2 + 2(n_0 + n_1)a + (n_0 + n_2) = 0$$

$$a = \frac{-2(n_0 + n_1) \pm \sqrt{4(n_0 + n_1)^2 + 4(n_0 + n_2)^2}}{-2(n_0 + n_2)}$$

Método de máxima verosimilitud

Simplificando, el estimador de máxima verosimilitud (MV) es:

$$\hat{a} = \frac{n_0 + n_1}{n_0 + n_2} \pm \sqrt{1 + \left(\frac{n_0 + n_1}{n_0 + n_2}\right)^2}$$

Como debe ocurrir que $\hat{a} > 1$, tomamos solamente la raíz positiva:

$$\hat{a} = \frac{n_0 + n_1}{n_0 + n_2} + \sqrt{1 + \left(\frac{n_0 + n_1}{n_0 + n_2}\right)^2}$$

En nuestro ejemplo $n_0 = 18$, $n_1 = 43$ y $n_2 = 39$. Por tanto:

$$\hat{a} = \frac{18 + 43}{18 + 39} + \sqrt{1 + \left(\frac{18 + 43}{18 + 39}\right)^2} = \frac{61}{57} + \sqrt{1 + \left(\frac{61}{57}\right)^2} = 2.5349$$

Método de máxima verosimilitud

En el caso particular de que $n_1 = n$, entonces $n_0 + n_2 = 0$, y el estimador anterior resulta ser $\hat{a} = \infty$

Este resultado era esperable, pues si $n_1 = n$ ello significa que todos los cangrejos tenían una única fusión y la función de verosimilitud quedaría reducida a:

$$L(a) = P(X = 1)^{n_1} = \left(\frac{a - 1}{a + 1} \right)^{n_1}$$

Es fácil comprobar que esta función es estrictamente creciente para $a > 1$; por tanto su máximo se alcanza para $\hat{a} = \infty$, lo que implica que:

$$\hat{P}(X = 1) = \lim_{a \rightarrow \infty} \frac{a - 1}{a + 1} = 1$$

es decir, si todos los cangrejos observados tienen una fusión, nuestra mejor estimación es que la probabilidad de tener una sola fusión es 1.

Método de máxima verosimilitud

PROBLEMA: ¿Cuál es el mejor estimador de todos los que hemos obtenido?

- Los estimadores analógicos no utilizan toda la información de la muestra: nuestros tres estimadores, o utilizan sólo p_0 , o sólo p_1 o sólo p_2
- El estimador por el método de los momentos no es calculable si $\bar{x} < 1$
- En nuestro ejemplo el estimador MV utiliza toda la información de la muestra y puede calcularse siempre.

En general se suele preferir el método de máxima verosimilitud porque tiene varias propiedades que lo hacen particularmente interesante.

Propiedades de los estimadores MV:

Los estimadores de máxima verosimilitud son preferibles a los estimadores obtenidos por analogía o por el método de los momentos (en algunos casos los estimadores obtenidos por los distintos métodos coinciden, aunque no ocurre así en general), ya que gozan de mejores propiedades:

- **Consistencia:** los estimadores MV son consistentes, esto es, a medida que aumenta el tamaño de la muestra es más probable que el valor del estimador esté cada vez más próximo al valor del parámetro.
- **Eficiencia:** Si $\hat{\theta}$ es un estimador de un parámetro θ , el error cuadrático medio se define como $ECM[\hat{\theta}] = E\left[\left(\hat{\theta} - \theta\right)^2\right]$. A medida que aumenta el tamaño de muestra, los estimadores MV tienen el menor error cuadrático medio de entre los estimadores posibles (en otras palabras, los estimadores MV tienden a producir, en promedio, valores más próximos al verdadero valor del parámetro θ que otros estimadores).
- **Normalidad asintótica:** a medida que aumenta el tamaño de la muestra, los estimadores MV tienden a tener distribución normal. Esta propiedad permite construir intervalos de confianza.