



Tema 3. estimación Puntual

Estadística II. Grado de Economía y ADE

Dr. Francisco Rabadán Pérez

www.pacorabadan.com



Esquema

1. Introducción: concepto de estimador
2. Propiedades (deseables) de los estimadores $\hat{\theta}$
 1. Consistencia.
 2. Insesgadez
 3. Eficiencia (Cota de Cramer-Rao)
 4. Suficiencia
 5. Invarianza
 6. Robustez

1. Introducción

- Población: $\xi: F(X; \theta_1, \theta_2, \dots, \theta_m)$. Tal que θ_i es PARÁMETRO: **No es variable aleatoria**
- Muestra: $X = \{x_1, x_2, \dots, x_n\}$, de donde obtenemos el **estadístico $T(X)$ que usamos como ESTIMADOR DE θ** , es decir

$T(X) = \hat{\theta}$, que **si es variable aleatoria** (número concreto para cada muestra).

Estimar es sinónimo de aproximación.

$Si \theta$ es $\left\{ \begin{array}{l} Valor Exacto \rightarrow Estimación Puntual \\ Intervalo \rightarrow Estimación por intervalos \end{array} \right.$

1. Error Cuadrático Medio (ECM)

$$ECM(\hat{\theta}) = E(\hat{\theta} - \theta)^2$$

Minimizar el ECM significa que $\hat{\theta}$ se aproxima a θ en media.

$$\begin{aligned} E(\hat{\theta} - \theta)^2 &= E[\hat{\theta} - \theta + E(\hat{\theta}) - E(\hat{\theta})]^2 = E\left[\left(\hat{\theta} - E(\hat{\theta})\right) - \left(\theta - E(\hat{\theta})\right)\right]^2 = \\ &= E[\hat{\theta} - E(\hat{\theta})]^2 + E[\theta - E(\hat{\theta})]^2 - 2E\left[\left(\hat{\theta} - E(\hat{\theta})\right)\left(\theta - E(\hat{\theta})\right)\right] = \\ &= V(\hat{\theta}) + E[\theta - E(\hat{\theta})]^2 - 2E\left(\hat{\theta} - E(\hat{\theta})\right)E[\theta - E(\hat{\theta})] = V(\hat{\theta}) + E[\theta - E(\hat{\theta})]^2 \end{aligned}$$

$$- 2E\left(\hat{\theta} - E(\hat{\theta})\right)E[\theta - E(\hat{\theta})] = 0 \text{ porque } E\left(\hat{\theta} - E(\hat{\theta})\right) = E(\hat{\theta}) - E(\hat{\theta}) = 0$$

$$\text{Y nos queda ... } ECM(\hat{\theta}) = V(\hat{\theta}) + E[\theta - E(\hat{\theta})]^2$$

siendo el sesgo: **Sesgo** = $E[\theta - E(\hat{\theta})]^2$

2. Propiedades (deseables) de los estimadores $\hat{\theta}$

Resumen

1. **Consistencia:** $\hat{\theta} \xrightarrow[n \rightarrow \infty]{} \theta$ (convergencia en probabilidad)
2. **Insesgadez:** $E(\hat{\theta}) = \theta \rightarrow ECM(\hat{\theta}) = V(\hat{\theta})$
3. **Eficiencia:** $V(\hat{\theta})$ es mínima
4. **Suficiencia:** $\hat{\theta}$ contiene en sí toda la información proporcionada por la muestra.

2.1. **Consistencia:** $\hat{\theta} \xrightarrow[n \rightarrow \infty]{} \theta$ (convergencia en probabilidad)

- Def: Principio lógico de que a medida que aumentamos la muestra, los valores que obtenemos de la estimación se van aproximando cada vez más a los valores reales de los parámetros poblacionales.
- Un estimador es **CONSISTENTE** cuando converge en probabilidad al verdadero valor del parámetro.

$$\hat{\theta} \xrightarrow[n \rightarrow \infty]{} \theta \leftrightarrow \begin{cases} P(|\hat{\theta} - \theta| < \varepsilon) \xrightarrow[n \rightarrow \infty]{} 1 \\ P(|\hat{\theta} - \theta| > \varepsilon) \xrightarrow[n \rightarrow \infty]{} 0 \end{cases}$$

- Sólo se puede comprobar (por la desigualdad de Chebychev) que $\hat{\theta}$ es consistente si $E(\hat{\theta}) = \theta$
- **INCONVENIENTE:** Lo único que nos dice es que utilicemos muestras grandes, pero **no cuanto mejora** la aproximación de $\hat{\theta}$ a θ al aumentar n .

2.1. Consistencia: $\hat{\theta} \xrightarrow[n \rightarrow \infty]{} \theta$ (convergencia en probabilidad)

Ejemplo

$$\xi: N(\mu, \sigma) \text{ y } \sigma^2 < \infty \xrightarrow[m.a.s(n)]{} X = \{x_1, x_2, \dots, x_n\}$$

¿ $\hat{\mu} = \bar{x}$ es consistente?

$\bar{x} = \hat{\mu}$ es consistente si $\bar{x} \xrightarrow{P} \hat{\mu} \Leftrightarrow P(|\bar{x} - \mu| < \varepsilon) \xrightarrow[n \rightarrow \infty]{} 1$, **comprobamos:**

1. $E[\bar{x}] = \mu$ -> es cierto (lo vimos en el tema 1)
2. Chebychev:

$$P(|\bar{x} - \mu| < \varepsilon) \geq 1 - \frac{V(\bar{x})}{\varepsilon^2} = 1 - \frac{\sigma^2/n}{\varepsilon^2} \xrightarrow[n \rightarrow \infty]{} 1$$

Luego es consistente

2.2. Inesgadez: $E(\hat{\theta}) = \theta \rightarrow ECM(\hat{\theta}) = V(\hat{\theta})$

- Se basa en el principio lógico de que los valores medios tienen una gran representatividad.
- $\hat{\theta}$ es insesgado si $E(\hat{\theta}) = \theta$, si esto no se cumple, aparece el sesgo

$$E(\hat{\theta}) = \theta + \overbrace{b(\theta)}^{\text{sesgo}} \begin{cases} \text{sesgo} > 0 \rightarrow \text{sobreestimar} \\ \text{sesgo} < 0 \rightarrow \text{infravalorar} \end{cases}$$

- Hay que ver que pasa con el sesgo cuando el tamaño de la muestra tiende a infinito...

- $E(\hat{\theta}) = \theta \rightarrow \hat{\theta}$ es insesgado
- $\hat{\theta}$ es asintóticamente insesgado si $\left\{ \begin{array}{l} 1. E(\hat{\theta}) = \theta + \overbrace{b(\theta)}^{\text{sesgo}} \\ 2. b(\theta) \xrightarrow[n \rightarrow \infty]{} 0 \end{array} \right.$

Nota: en estadística solemos considerar que $n \rightarrow \infty$ cuando $n \geq 30$.

2.2. Insesgadez: $E(\hat{\theta}) = \theta \rightarrow ECM(\hat{\theta}) = V(\hat{\theta})$

Ejemplo: Sea $\xi: N(\mu, \sigma)$ ¿ \bar{x} es estimador insesgado de μ ?

$$E(\bar{x}) = E\left(\frac{x_1 + x_2 + \dots + x_n}{n}\right) = \frac{1}{n}nE(x_i) = \frac{1}{n}n\mu = \mu$$

Luego \bar{x} es insesgado porque $E(\bar{x}) = \mu$ (tema 1)

2.2. Inesgadez: $E(\hat{\theta}) = \theta \rightarrow ECM(\hat{\theta}) = V(\hat{\theta})$

Ejemplo 2: Sea $\xi: N(\mu, \sigma)$ ¿ s^2 es estimador inesgado de σ^2 ?

$$E(s^2) = E\left[\frac{\sum x_i^2}{n} - \bar{x}^2\right] = \frac{n-1}{n}\sigma^2 = \sigma^2 - \underbrace{\sigma^2/n}_{\text{sesgo}}$$

Luego es sesgado, pero como

$$b(x) = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0$$

también es asintóticamente inesgado.

Nota: en estadística solemos considerar que $n \rightarrow \infty$ cuando $n \geq 30$.

2.2. Insegadez: $E(\hat{\theta}) = \theta \rightarrow ECM(\hat{\theta}) = V(\hat{\theta})$

Ejemplo 3: Sea $\xi: N(\mu, \sigma)$ ¿ s_1^2 es estimador insegado de σ^2 ?

$$s_1^2 = \frac{\sum (x_i - \bar{x})^2}{n - 1} = \frac{n}{n - 1} \frac{\sum (x_i - \bar{x})^2}{n} = \frac{n}{n - 1} s^2$$

$$E(s_1^2) = \frac{n}{n - 1} E(s^2) = \frac{n}{n - 1} \frac{n - 1}{n} \sigma^2 = \sigma^2$$

Luego es, insegado

$$b(x) = 0$$


2.3. **Eficiencia:** $V(\hat{\theta})$ es mínima $\left\{ \begin{array}{l} \hat{\theta} \text{ es insesgado} \\ y \\ V(\hat{\theta}) \text{ es mínima} \end{array} \right.$

Para ver si la varianza del estimador es mínima se calcula la **COTA DE CRAMER-RAO**, que es un valor *único para cada tipo de distribución poblacional y para cada parámetro*.

La **Cota de Cramer-Rao (CCR)**, indica la *varianza mínima que debe poseer cualquier estimador del parámetro poblacional*.

$$V(\hat{\theta}) \geq CCR = \frac{1}{nE \left[\frac{\partial \ln[f(X, \theta)]}{\partial \theta} \right]^2}$$

Objetivo: pretende que la distribución de $\hat{\theta}$ esté muy concentrada en θ , es decir, que haya la menor dispersión posible.



2.3. Eficiencia: $\min V(\hat{\theta})$

$$V(\hat{\theta}) \geq CCR = \frac{1}{nE \left[\frac{\partial \ln[f(X, \theta)]}{\partial \theta} \right]^2}$$

Ejemplo1: Sea $\xi: N(\mu, \sigma)$ ¿ \bar{x} es eficiente?

1º ¿ Insesgado?: si, lo hemos visto. $E(\bar{x}) = \mu$

2º. Cota de Cramer Rao:

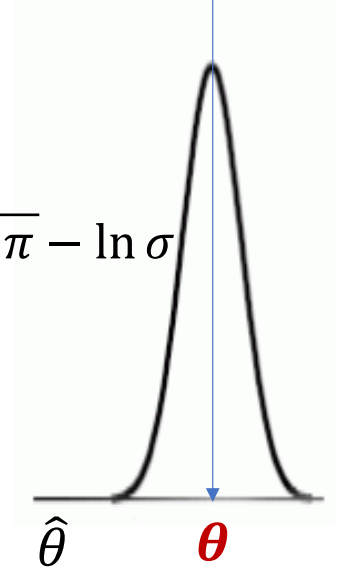
1. **Función de densidad (o de cuantía):** $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$

2. $\ln[f(x)] = -\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2 \ln[e] - \ln[\sqrt{2\pi}] - \ln[\sigma] = -\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2 = \frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2 - \ln \sqrt{2\pi} - \ln \sigma$

3. $\frac{\partial \ln[f(x)]}{\partial \mu} = \frac{2}{2\sigma^2}(x - \mu) = \frac{(x-\mu)}{\sigma^2}$

4. $E \left[\frac{\partial \ln[P(\xi=x)]}{\partial \mu} \right]^2 = E \left(\frac{(x-\mu)}{\sigma^2} \right)^2 = \frac{1}{(\sigma^2)^2} E(x - \mu)^2 = \frac{1}{(\sigma^2)^2} \sigma^2 = \frac{1}{\sigma^2}$

5. $CCR = \frac{1}{nE \left[\frac{\partial \ln[f(X,\theta)]}{\partial \mu} \right]^2} = \frac{1}{n \frac{1}{\sigma^2}} = \frac{\sigma^2}{n}$



Como $CCR = \frac{\sigma^2}{n} = V(\bar{x}) = \frac{\sigma^2}{n}$ y además \bar{x} Insesgado $\rightarrow \bar{x}$ ES EFICIENTE

2.3. Eficiencia: $\min V(\hat{\theta})$

Ejemplo: Sea $\xi: B(5, \pi) \rightarrow m. a. s. (5)$ ¿ $\hat{\pi} = \frac{\bar{x}}{5}$ es eficiente?

1º \hat{p} es Insesgado. $E(\hat{\pi}) = E\left(\frac{\bar{x}}{5}\right) = \frac{1}{5} E\left(\frac{x_1 + x_2 + \dots + x_n}{5}\right) = \frac{1}{5} \frac{5 \cdot E(\xi)}{5} = \frac{1}{5} n\pi = \frac{1}{5} 5\pi = \pi$

$$V(\hat{\pi}) = V\left(\frac{\bar{x}}{5}\right) = \frac{1}{5^2} V\left(\frac{x_1 + x_2 + \dots + x_n}{5}\right) = \frac{1}{5^2} \frac{1}{5^2} V(x_1 + x_2 + \dots + x_n) = \frac{1}{5^4} 5(V(\xi)) = \frac{\pi(1-\pi)}{5^2}$$

2º. Cota de Cramer Rao:

1. **Función de cuantía:** $P(\xi = x) = \binom{5}{x} \pi^x (1-\pi)^{5-x}$

2. $\ln[P(\xi = x)] = \ln\binom{5}{x} + x \ln \pi + (5-x) \ln(1-\pi)$

3. $\frac{\partial \ln[P(\xi=x)]}{\partial \pi} = \frac{x}{\pi} - \frac{5-x}{1-\pi} = \dots = \frac{x-5\pi}{\pi(1-\pi)}$

4. $E\left[\frac{\partial \ln[P(\xi=x)]}{\partial \pi}\right]^2 = E\left[\frac{x-5\pi}{\pi(1-\pi)}\right]^2 = \frac{1}{\pi^2(1-\pi)^2} E[x - 5\pi]^2 = \frac{V(\xi)}{\pi^2(1-\pi)^2} = \frac{5\pi(1-\pi)}{\pi^2(1-\pi)^2} = \frac{5}{\pi(1-\pi)}$

5. $CCR = \frac{1}{nE\left[\frac{\partial \ln[P(\xi=x)]}{\partial \pi}\right]^2} = \frac{1}{5 \frac{5}{\pi(1-\pi)}} = \frac{1}{5^2}$

Como $CCR = V(\hat{p})$ y además \hat{p} es Insesgado $\rightarrow \hat{p}$ ES EFICIENTE

2.3. Eficiencia: $\min V(\hat{\theta})$

- Diremos que un estimador $\hat{\theta}$ es asintóticamente eficiente si su varianza converge a la CCR cuando el tamaño de la muestra tiende a infinito

$\hat{\theta}$ asintóticamente eficiente si $V(\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} CCR$

2.4. **Suficiencia:** $\hat{\theta}$ contiene en sí toda la información proporcionada por la muestra.

- $\hat{\theta}$ es suficiente cuando **contiene toda la información** que hay en la muestra respecto al parámetro poblacional desconocido.
- **Si la población es $\xi: N(\mu, \sigma)$** , son estimadores suficientes:

$$\hat{\mu} = \bar{x}$$

$$\hat{\sigma}^2 = S^2$$

Más en aula virtual URJC y (Martín Pliego ,2005)

2.5. **Invarianza:** $\hat{\theta}$ no varía ante transformaciones.

- $\hat{\theta}$ es invariante si **no varía ante transformaciones.**

$$\hat{\sigma} = s \xrightarrow[\text{transformación: } ^2]{\quad} \hat{\sigma}^2 = S^2$$

Más en aula virtual URJC y (Martín Pliego ,2005)

2.6. **Robustez:** $\hat{\theta}$ en relación a los supuestos del modelo (hipótesis iniciales)

- $\hat{\theta}$ es robusto si no le afectan significativamente alteraciones en los supuestos de un modelo estadístico (hipótesis iniciales).
- Ejemplos de supuestos:
 - Igualdad de varianzas (necesario para la prueba t de igualdad de medias)
 - Población: Normal, Binomial, etc...
- Veremos bastantes más en las asignaturas de Estadística Superior y en Econometría

Bibliografía

- Martín Pliego, Fundamentos de Inferencia Estadística, Editorial AC, 3ªEd, 2005
- Otros recursos en www.pacorabadan.com