

# Estadística II

Temas 2 y 3. Estimación puntual, suficiencia e información

Facultad de Ciencias de la Economía y de la Empresa (FCEE)

Curso 2025–2026 · 4.5 ECTS · 2º cuatrimestre

**Francisco Rabadán Pérez · Raquel Ibar-Alonso · Ester Muñoz Céspedes**

Departamento de Economía Aplicada I e Historia e Instituciones Económicas

# Tema 3 · Objetivo

Al terminar este tema podrás:

- Comprender qué es un estimador y distinguir **parámetro, estadístico, estimación y error de estimación**.
- Medir la **calidad de un estimador** con el error cuadrático medio (**ECM**) y su descomposición: **Varianza + Sesgo<sup>2</sup>**.
- Identificar y aplicar **propiedades clave: insesgadez, consistencia y eficiencia (cota de Cramér–Rao)**.
- Introducir la **suficiencia** como “**resumen sin pérdida**” y usar el **criterio de factorización de Fisher–Neyman** en ejemplos sencillos.

Cómo leer estas etiquetas

CORE

PLUS

ANEXO

**CORE:** ideas y procedimientos que sostienen el curso entero y que se practican de forma recurrente.

**PLUS:** material para profundizar o reforzar intuición; ayuda a consolidar.

**ANEXO:** material de referencia o consulta.

# Tema 2 - 3 · Esquema

Qué vamos a construir paso a paso:

- **Bloque A. Estimación puntual:** parámetro, estimador, estimación y error de estimación
- **Bloque B. Calidad del estimador:**  $ECM = Var + Sesgo^2$
- **Bloque C. Propiedades clave:** insesgadez, consistencia y eficiencia
- **Bloque D. Cota de Cramér–Rao (CCR):** interpretación y uso básico
- **Bloque E. Suficiencia e información:** idea de estadístico suficiente + Fisher–Neyman (visión operativa)
- **Cierre:** resumen + tabla de fórmulas clave

# Breviario

- $\theta$ : parámetro poblacional desconocido (valor fijo).
- $\hat{\theta}$ : estimador de  $\theta$  (variable aleatoria, depende de la muestra).
- **ECM**: Error cuadrático medio
- $L(\theta|\mathbf{x})$ : función de verosimilitud (misma expresión que la conjunta, vista como función de  $\theta$  con  $\mathbf{x}$  fijo).
- $\ln L(\theta|\mathbf{x})$ : logaritmo neperiano de la función de verosimilitud (simplifica derivadas/productos).
- $I_n(\theta)$ : información de Fisher.
- **CCR**: Cota de Cramér-Rao.

# **Sección A. Conceptos básicos de estimación puntual**


# Parámetro, estimador y estimación

CORE

- **Parámetro ( $\theta$ ):** valor fijo **desconocido** de la población (p. ej.,  $\mu$ ,  $p$ ,  $\sigma^2$ ).
- **Estimador ( $\hat{\theta}$ ):** función de la muestra para aproximar  $\theta$  (variable aleatoria).
- **Estimación:** el **valor numérico** que toma  $\hat{\theta}$  cuando usamos los datos observados de una muestra concreta.
- Error de estimación:  $\hat{\theta} - \theta$  (no se conoce porque  $\theta$  es desconocido).




# Error de estimación



- **Error de estimación:**  $\hat{\theta} - \theta$
- Mide la **diferencia** entre lo que **estimamos** y el **valor real** del parámetro.
- **No es observable** directamente porque  $\theta$  es desconocido.
- Se analiza el **comportamiento de  $\hat{\theta}$** : sesgo, varianza y ECM.

# ¿Qué es un “buen” estimador?



- Queremos que  $\hat{\theta}$  esté **cerca de  $\theta$**
- “Cerca” tiene dos componentes:
  - **Sesgo (bias):** desplazamiento **sistemático** respecto a  $\theta$
  - **Varianza:** **dispersión** de  $\hat{\theta}$  entre muestras.
- Un **buen estimador** tiene **bajo sesgo y baja varianza**.

# Sesgo del estimador


- **Sesgo de  $\hat{\theta}$ :**

$$\text{Sesgo}(\hat{\theta}) = E(\hat{\theta}) - \theta$$

- **Interpretación:** si repetimos el muestreo muchas veces, la diferencia entre el promedio de  $\hat{\theta}$  y el valor verdadero  $\theta$ .

- $\hat{\theta}$  es Insesgado si y solo si:



$$E(\hat{\theta}) = \theta$$



- **Ejemplos:**

- Si  $E(\hat{\theta}) = \theta + 0,5 \rightarrow \text{sesgo} = 0,5$   
( $\hat{\theta}$  sobreestima  $\theta$ )
- Si  $E(\hat{\theta}) = \theta - 0,5 \rightarrow \text{sesgo} = -0,5$   
( $\hat{\theta}$  infraestima  $\theta$ )

# Varianza del estimador




- Varianza de  $\hat{\theta}$ :

$$V(\hat{\theta})$$

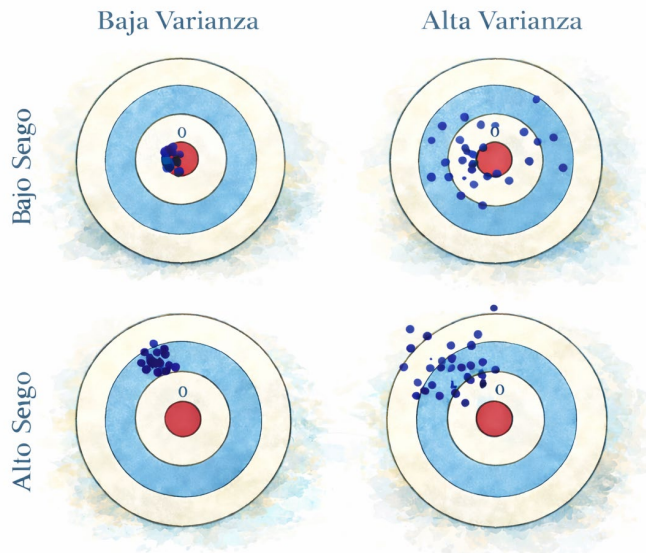
- **Interpretación:** mide la dispersión de  $\hat{\theta}$  cuando repetimos el muestreo.
- **Baja varianza**  $\Rightarrow$  estimaciones **estables** (poco cambian entre muestras).
- En general, al aumentar  $n$ , la varianza tiende a disminuir.

# Ejercicios rápidos



- Si  $E(\hat{\theta}) = \theta$ , entonces el estimador  $\hat{\theta}$  es:  
A) consistente B) insesgado C) eficiente D) suficiente
- “Alta varianza” significa que  $\hat{\theta}$  cambia mucho entre muestras  
A) Verdadero B) Falso
- Si  $E(\hat{\theta}) = \theta + 0,5$ , el sesgo es:  
A)  $-0,5$  B)  $0$  C)  $0,5$  D) depende de  $n$
- ¿Qué representa mejor el sesgo?  
A) dispersión de  $\hat{\theta}$   
B) desplazamiento medio de  $\hat{\theta}$  respecto a  $\theta$   
C) el error  $\hat{\theta} - \theta$  observado en una muestra  
D) la varianza de la población

# Ejercicios rápidos



- Si  $E(\hat{\theta}) = \theta$ , entonces el estimador es:

A) consistente B) insesgado  C) eficiente D) suficiente

- “Alta varianza” significa que  $\hat{\theta}$  cambia mucho entre muestras

A) Verdadero  B) Falso

- Si  $E(\hat{\theta}) = \theta + 0,5$ , el sesgo es:

A)  $-0,5$  B)  $0$  C)  $0,5$   D) depende de  $n$

- ¿Qué representa mejor el sesgo?

A) dispersión de  $\hat{\theta}$

B) desplazamiento medio respecto a  $\theta$

C) el error  $\hat{\theta} - \theta$  observado en una muestra

D) la varianza de la población

# Error cuadrático medio (ECM)

- **En una muestra** no conocemos  $\theta$ , pero sí podemos **evaluar la calidad media de  $\hat{\theta}$**  si repitiésemos el muestreo.
- Una **medida estándar** es el error cuadrático medio (ECM), o en inglés “*Mean Squared Error*” (MSE)
- Mide el error medio de estimación (al cuadrado) y se puede descomponer en varianza y sesgo<sup>2</sup>.

- **Definición**

$$ECM(\hat{\theta}) = E \left[ (\hat{\theta} - \theta)^2 \right]$$

# ECM = Varianza + Sesgo<sup>2</sup>

- El ECM combina dos fuentes de error:
  - Varianza:** inestabilidad de  $\hat{\theta}$  entre muestras.
  - Sesgo<sup>2</sup>:** desplazamiento sistemático de  $E[\hat{\theta}]$  respecto a  $\theta$ .
- El mismo ECM puede resultar de combinaciones distintas (**trade-off**).

## Definición

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

## Identidad

$$ECM(\hat{\theta}) = V(\hat{\theta}) + [E(\hat{\theta}) - \theta]^2$$

$$ECM(\hat{\theta}) = V(\hat{\theta}) + [Sesgo(\hat{\theta})]^2$$

1. Sumo y resto  $E(\hat{\theta})$

$$\hat{\theta} - \theta = (\hat{\theta} - E(\hat{\theta})) + (E(\hat{\theta}) - \theta)$$

¿Por qué?

2. Elevo al cuadrado y tomo esperanza:

$$E[(\hat{\theta} - \theta)^2] = E[(\hat{\theta} - E(\hat{\theta}))^2] + 2E[(\hat{\theta} - E(\hat{\theta}))(E(\hat{\theta}) - \theta)] + E[(E(\hat{\theta}) - \theta)^2]$$

3.  $E[(\hat{\theta} - E(\hat{\theta}))(E(\hat{\theta}) - \theta)] =$

$$\begin{aligned} &= E[(\hat{\theta}E(\hat{\theta}) - \hat{\theta}\theta - [E(\hat{\theta})]^2 + E(\hat{\theta})\theta)] = \\ &= [E(\hat{\theta})]^2 - E(\hat{\theta})\theta - [E(\hat{\theta})]^2 + E(\hat{\theta})\theta = 0 \\ &(E(\hat{\theta}) - \theta) \cdot E[(\hat{\theta} - E(\hat{\theta}))] = 0 \end{aligned}$$

4.  $E[(\hat{\theta} - \theta)^2] = E[(\hat{\theta} - E(\hat{\theta}))^2] + E[(E(\hat{\theta}) - \theta)^2] =$

$$E[(\hat{\theta} - E(\hat{\theta}))^2] + (E(\hat{\theta}) - \theta)^2 = V(\hat{\theta}) + [Sesgo(\hat{\theta})]^2$$

$$ECM(\hat{\theta}) = V(\hat{\theta}) + (Sesgo(\hat{\theta}))^2$$

# Ejercicio corto A3 · ECM = Varianza + Sesgo<sup>2</sup>

CORE

## Enunciado

Sea un estimador  $\hat{\theta}$  tal que:

- $E[\hat{\theta}] = \theta + 0,2$
- $V[\hat{\theta}] = 1/n$

- a) Calcula el sesgo y el sesgo<sup>2</sup>.
- b) Calcula el ECM como función de  $n$ .
- c) ¿Para qué valores de  $n$  se cumple  $ECM < 0,1$ ?

## Respuesta

Dado  $E[\hat{\theta}] = \theta + 0,2$  y  $V[\hat{\theta}] = 1/n$

**a)**  $\text{Sesgo}(\hat{\theta}) = E(\hat{\theta}) - \theta = 0,2$ ;  $(\text{Sesgo}(\hat{\theta}))^2 = 0,04$

**b)**  $ECM(\hat{\theta}) = V(\hat{\theta}) + (\text{Sesgo}(\hat{\theta}))^2 = \frac{1}{n} + 0,04$

**c)**  $\frac{1}{n} + 0,04 < 0,1 \rightarrow \frac{1}{n} < 0,06 \rightarrow n > \frac{1}{0,06} = 16,66 \dots$

Por tanto,  $n \geq 17$

# Propiedades deseables de un estimador

## Evaluación del Estimador

✓ Insesgadez

✓ Consistencia

✓ Eficiencia

✓ Suficiencia

✓ Invarianza

✓ Robustez

Un estimador  $\hat{\theta}$  se suele evaluar por:

- **Insesgadez:**  $E(\hat{\theta}) = \theta$
- **consistencia:**  $\hat{\theta} \xrightarrow{p} \theta$  cuando  $n \rightarrow \infty$
- **Eficiencia:** varianza pequeña (entre insesgados)
- **Suficiencia:**  $T(X)$  recoge toda la información sobre  $\theta$
- **Invarianza :** si cambias la escala del parámetro, la estimación se obtiene aplicando el mismo cambio al estimador ( $g(\theta) \rightarrow g(\hat{\theta})$ )
- **Robustez:** poca sensibilidad a pequeños cambios (valores atípicos / supuestos / *outliers*)



# Sección B. Insegadez y consistencia

# Insegadez ≠ “siempre cerca”

- Insegado significa:

$$E(\hat{\theta}) = \theta$$

- Pero una estimación concreta puede estar lejos si hay alta varianza.
- **Idea clave: insegadez habla de promedio, no de precisión.**



# Insesgadez: dos matices útiles

- Insesgado:

$$E(\hat{\theta}) = \theta$$

- En ese caso, el error cuadrático medio mide solo la **variabilidad entre muestras**.

$$\hat{\theta} \text{ insesgado} \rightarrow \text{ECM}(\hat{\theta}) = V(\hat{\theta})$$

- Insesgadez asintótica:

$$E(\hat{\theta}) - \theta \rightarrow 0 \quad (n \rightarrow \infty)$$

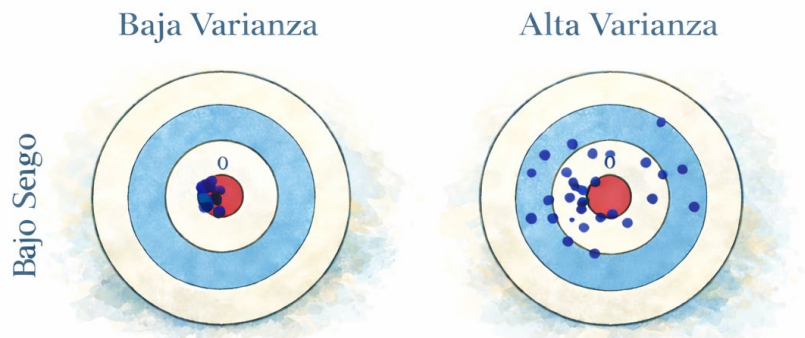
- Ejemplo clásico (varianza muestral):

$$E(S^2) = \frac{n-1}{n} \sigma^2 \Rightarrow$$

$$\text{sesgo}(S^2) = E(S^2) - \sigma^2 = \frac{n-1}{n} \sigma^2 - \sigma^2 = \sigma^2 \left( \frac{n-1-n}{n} \right) = -\frac{\sigma^2}{n}$$

$$\text{Sesgo}(S^2) = -\frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0$$

**Conclusión:**  $S^2$  es sesgado, pero asintóticamente insesgado.




El estadístico insesgado correspondiente:  $S_1^2$

# Consistencia (idea y definición)

## Intuición

- Un estimador  $\hat{\theta}$  es consistente si, cuando aumenta el tamaño muestral  $n$ ,  $\hat{\theta}$  se aproxima a  $\theta$ .
- **Idea clave:** con muestras grandes, el error  $\hat{\theta} - \theta$  tiende a hacerse pequeño.



## Definición (convergencia en probabilidad):

$$\hat{\theta} \xrightarrow{p} \theta \quad (n \rightarrow \infty)$$

- Equivalente operacional: para todo  $\varepsilon > 0$ ,

$$P(|\hat{\theta} - \theta| > \varepsilon) \rightarrow 0$$

- **Decisión:** para cualquier  $\varepsilon > 0$ , miras qué ocurre con  $P(|\hat{\theta} - \theta| > \varepsilon)$  cuando  $n \rightarrow \infty$ ; Si tiende a 0 para todo  $\varepsilon$ , entonces  $\hat{\theta}$  es consistente.
- **Lectura:** la probabilidad de “fallar por más de  $\varepsilon$ ” se hace casi cero cuando  $n$  crece.

# ¿Cómo comprobar consistencia? (regla práctica)

CORE

**Regla útil (suficiente): si se cumple que, cuando  $n \rightarrow \infty$ ,**

- $E(\hat{\theta}) \rightarrow \theta$ ; (*Sesgo*( $\hat{\theta}$ )  $\rightarrow 0$ )
- $V(\hat{\theta}) \rightarrow 0$

Entonces  $\hat{\theta}$  es consistente.

- **Idea clave:** la distribución de  $\hat{\theta}$  se concentra alrededor de  $\theta$ .

**Ejemplo de 1 minuto**


Sea  $E(\hat{\theta}) = \theta + 1/n$ ;  $V(\hat{\theta}) = 4/n$

Si  $n \rightarrow \infty$ ,

- $E(\hat{\theta}) \rightarrow \theta$
- $V(\hat{\theta}) \rightarrow 0$

Y, por tanto,  $\hat{\theta}$  es consistente

- **Idea informal:** Si la dispersión se hace pequeña ( $Var \rightarrow 0$ ) y el centro se acerca a  $\theta$  (*Sesgo*( $\hat{\theta}$ )  $\rightarrow 0$ ), entonces  $\hat{\theta}$  termina “pegándose” a  $\theta$ .



# Ejercicios rápidos B1 · Consistencia

1. Si  $\hat{\theta} \xrightarrow{p} \theta$ , entonces:

- a)  $E(\hat{\theta}) = 0$  para todo  $n$ .
- b)  $P(|\hat{\theta} - \theta| > \varepsilon) \rightarrow 0$  para todo  $\varepsilon > 0$ .
- c)  $V(\hat{\theta})$  es constante
- d)  $\hat{\theta} = 0$  siempre

2. Si  $E[\hat{\theta}] = \theta + 1/n$  y  $V[\hat{\theta}] = 1/n$ , entonces  $\hat{\theta}$  es:

- a) sesgado y no consistente
- b) insesgado y consistente
- c) sesgado y consistente
- d) insesgado y no consistente

3. ¿Cuál de estas condiciones es suficiente para consistencia?

- a)  $E(\hat{\theta}) = 0$
- b)  $V(\hat{\theta}) \rightarrow 0$
- c)  $E(\hat{\theta}) \rightarrow \theta$  y  $V(\hat{\theta}) \rightarrow 0$
- d)  $V(\hat{\theta})$  mínima.

4. En términos intuitivos, consistencia significa que al crecer  $n$  :

- a) El sesgo aumenta
- b) Las estimaciones se dispersan más
- c) El estimador se acerca a  $\theta$  con “alta probabilidad”
- d) El estimador es suficiente

# Ejercicios rápidos B1 · Consistencia

CORE

1. Si  $\hat{\theta} \xrightarrow{p} \theta$ , entonces:

- a)  $E(\hat{\theta}) = 0$  para todo  $n$ .
- b)  $P(|\hat{\theta} - \theta| > \varepsilon) \rightarrow 0$  para todo  $\varepsilon > 0$ .
- c)  $V(\hat{\theta})$  es constante
- d)  $\hat{\theta} = 0$  siempre

2. Si  $E[\hat{\theta}] = \theta + 1/n$  y  $V[\hat{\theta}] = 1/n$ , entonces  $\hat{\theta}$  es:

- a) sesgado y no consistente
- b) insesgado y consistente
- c) sesgado y consistente
- d) insesgado y no consistente

3. ¿Cuál de estas condiciones es suficiente para consistencia?

- a)  $E(\hat{\theta}) = 0$
- b)  $V(\hat{\theta}) \rightarrow 0$
- c)  $E(\hat{\theta}) \rightarrow \theta$  y  $V(\hat{\theta}) \rightarrow 0$
- d)  $V(\hat{\theta})$  mínima.

4. En términos intuitivos, consistencia significa que al crecer  $n$  :

- a) El sesgo aumenta
- b) Las estimaciones se dispersan más
- c) El estimador se acerca a  $\theta$  con “alta probabilidad”
- d) El estimador es suficiente

## Respuestas


# Insegadez y consistencia: no son lo mismo

## Insegadez (para cada $n$ )

- $E(\hat{\theta}) = \theta$
- Habla del **promedio** de  $\hat{\theta}$  en muestreos repetidos.
- No garantiza baja varianza.

## Consistencia (cuando $n \rightarrow \infty$ )

- $\hat{\theta} \xrightarrow{p} \theta$
- Habla del **comportamiento con muestras grandes**.
- Puede haber **sesgo para  $n$  finito**, pero *sesgo*  $\rightarrow 0$  cuando  $n \rightarrow \infty$ .



## Mini-test

¿Puede un estimador ser consistente y sesgado (para  $n$  finito)? Sí

# Ejercicio corto B2

Sea  $\hat{\theta}_n$  tal que:

$$E(\hat{\theta}_n) = \theta + \frac{2}{n}, \quad V(\hat{\theta}_n) = \frac{1}{n}$$

- ¿Es insesgado para  $n$  finito?
- ¿Es consistente? Justifica con condiciones suficientes (la regla práctica).
- Calcula el ECM y su límite cuando  $n \rightarrow \infty$ .

## Solución

a) No.

$$\text{Sesgo}(\hat{\theta}_n) = E(\hat{\theta}_n) - \theta = \frac{2}{n} \neq 0$$

## Solución

b) Sí, es consistente, porque:

$$E(\hat{\theta}_n) \rightarrow \theta \text{ y } V(\hat{\theta}_n) \rightarrow 0 \text{ (} n \rightarrow \infty \text{)}$$

c)

$$ECM(\hat{\theta}_n) = V(\hat{\theta}_n) + (\text{Sesgo}(\hat{\theta}_n))^2 = \frac{1}{n} + \left(\frac{2}{n}\right)^2 = \frac{1}{n} + \frac{4}{n^2}$$

$$\lim_{n \rightarrow \infty} ECM(\hat{\theta}_n) = \lim_{n \rightarrow \infty} \left(\frac{1}{n} + \frac{4}{n^2}\right) = 0$$

**Nota:** al cumplirse b) y c)  $\Rightarrow \hat{\theta}_n \xrightarrow{p} \theta$

## Idea clave

Consistencia no exige insesgadez para  $n$  finito: basta con que el sesgo  $\rightarrow 0$  y la varianza  $\rightarrow 0$  cuando  $n$  aumenta.

# Sección C. Eficiencia y cota de Cramér–Rao

# Eficiencia del estimador $\hat{\theta}$

- **El estimador eficiente** es el de mínima varianza: Entre los estimadores insesgados de un mismo parámetro poblacional, el eficiente es aquel que tiene mínima varianza.  
Para saber si un estimador es el eficiente se puede comparar con la **Cota de Cramér–Rao (CCR)**, lo vemos más adelante.

- **Eficiencia relativa:** Un estimador  $\hat{\theta}_1$  es **más eficiente** que otro  $\hat{\theta}_2$  si tiene **menor varianza:**

$$V(\hat{\theta}_1) < V(\hat{\theta}_2)$$

La eficiencia relativa solo tiene sentido comparar estimadores insesgados. Si los estimadores comparados son sesgados, se prefiere el de menor Error Cuadrático Medio (ECM).

# Eficiencia del estimador (idea operativa)

- En sentido amplio, diremos que  $\hat{\theta}_1$  es más eficiente que otro  $\hat{\theta}_2$  si tiene menor ECM:

$$ECM(\hat{\theta}) = V(\hat{\theta}) + (\text{Sesgo}(\hat{\theta}))^2$$

- Si ambos son insesgados, entonces comparar eficiencia equivale a **comparar Varianzas**, porque

$$ECM(\hat{\theta}) = V(\hat{\theta})$$

- **Interpretación:** entre estimadores, preferimos el que produce **estimaciones más estables** (menos dispersas).

## mini-ejemplo

Dos estimadores insesgados de  $\theta$ :

- $V(\hat{\theta}_1) = 0,20$
  - $V(\hat{\theta}_2) = 0,05$
- $\hat{\theta}_2$  es más eficiente

## Eficiencia vs consistencia

- **Consistencia:** con  $n$  grande  $\hat{\theta} \rightarrow \theta$ .
- **Eficiencia:** para un  $n$  dado, entre insesgados, preferimos el que tiene **menor varianza** (más precisión).

# Cota de Cramér–Rao (CCR)

## Intuición:

- La CCR proporciona un **límite inferior para la varianza** de cualquier estimador de  $\theta$  **conocida la distribución poblacional** (derivable).
- **Interpretación:** existe una precisión “máxima” (mínima varianza) que no se puede superar dadas la distribución y el tamaño muestral ( $n$ ).
- **Para todo estimador insesgado,**  $V(\hat{\theta}) \geq CCR(\theta)$ . Si alcanza la igualdad, es eficiente en sentido CCR.

- **Información de Fisher:**  $I_n(\theta)$  de una m.a.s( $n$ )


$$I_1(\theta) = E \left[ \left( \frac{\partial(\ln f(X; \theta))}{\partial \theta} \right)^2 \right]; \quad I_n(\theta) = nI_1(\theta)$$

La CCR se define:

- Si  $\hat{\theta}$  es insesgado:  $CCR(\theta) = \frac{1}{I_n(\theta)}$
- Si  $\hat{\theta}$  es sesgado:  $CCR(\theta) = \frac{(1+b'(\theta))^2}{I_n(\theta)}$

Donde


- $b(\theta) = E(\hat{\theta}) - \theta$  y
- $b'(\theta)$  es la derivada primera del sesgo.



Bajo condiciones regulares (supuestos técnicos para que exista  $I(\theta)$  y sea válida la derivación).

# CCR en una muestra i.i.d. (tamaño n)

Si  $V(\hat{\theta}) = CCR(\theta)$  entonces  $\hat{\theta}$  es el eficiente



Ojo: Puede existir un estimador  $\hat{\theta}$  que sea el eficiente y que no cumpla la igualdad:  $V(\hat{\theta}) = CCR(\theta)$

## Explicación intuitiva:

- Para una misma población:

$$\text{Si } n \uparrow \Rightarrow I_n(\theta) \uparrow \Rightarrow CCR(\theta) \downarrow$$

- **consecuencia:** la varianza mínima posible puede ser menor para una muestra mayor.

**Idea:** más datos  $\Rightarrow$  más información  $\Rightarrow$  mayor precisión potencial.

$I_1(\theta)$  es información esperada por observación; el *score* varía con los datos, pero su esperanza (información) es la misma para cada  $x_i$ .

# Cálculo de $I_n(\pi)$ (Bernoulli)

idea operativa:

$$I_n(\theta) = n \cdot E \left[ \left( \frac{\partial(\ln f(x; \theta))}{\partial \theta} \right)^2 \right]$$

Pasos:

1. Escribe  $f(x; \theta)$  (una observación)
2. Calcula  $\ln f(x; \theta)$
3. Deriva:  $\frac{\partial(\ln f(x; \theta))}{\partial \theta}$
4. Eleva al cuadrado y toma esperanza.
5. Multiplica por  $n$ .

Si  $x \sim B(1, \pi)$ ; estimador  $p$ :

$$1. f(x; \pi) = \pi^x (1 - \pi)^{1-x}, x \in \{0, 1\}$$

$$2. \ln f(x; \pi) = x \ln \pi + (1 - x) \ln(1 - \pi)$$

$$3. \frac{\partial(\ln f(x; \pi))}{\partial \pi} = \frac{x}{\pi} - \frac{1-x}{1-\pi} = \frac{x-\pi}{\pi(1-\pi)}$$

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

$$5. I_n(\pi) = n \cdot \frac{1}{\pi(1-\pi)} = \frac{n}{\pi(1-\pi)}$$

- **Nota:** Si  $x \sim B(1, \pi)$ ; entonces  $V(x) = \pi(1 - \pi)$ ;

# CCR en $B(1,\pi)$ : varianza mínima para estimadores insesgados

## Planteamiento:

Si  $x_1, \dots, x_n \sim B(1, \pi)$  v.a.i.i.d. y  $\hat{\pi}$  es un estimador insesgado de  $\pi$ , entonces:

- Ya hemos calculado:

$$I_n(\pi) = \frac{n}{\pi(1-\pi)}$$

- Calculamos la CCR ( $\pi$ ) para estimador insesgado:

$$CCR(\pi) = \frac{1}{I_n(\pi)} = \frac{\pi(1-\pi)}{n}$$

- Aplicando la CCR:

$$V(\hat{\pi}) \geq CCR(\pi)$$

$$V(\hat{\pi}) = V(p) = \frac{\pi(1-\pi)}{n} = CCR(\pi)$$

Por lo tanto,  $\hat{\pi} = p$  es el estimador eficiente de  $\pi$

## Interpretación (2 líneas):

- Ningún estimador insesgado de  $\pi$  puede tener varianza menor que  $\frac{\pi(1-\pi)}{n}$
- A mayor  $n$ , menor cota  $\rightarrow$  mayor precisión potencial

# Ejercicio corto C2 · CCR en $B(1,\pi)$

CORE

## Planteamiento:

Si  $x_1, \dots, x_n \sim B(1, \pi)$  v.a.i.i.d. y define el estimador:

$$p = \frac{1}{n} \sum_{i=1}^n x_i$$

1. Calcula  $E(p)$ . ¿Es  $p$  insesgado para  $\pi$ ?
2. Calcula  $V(p)$
3. Compara  $V(p)$  con la CCR:

$$CCR(\pi) = \frac{\pi(1 - \pi)}{n}$$

¿ $p$  alcanza la cota?

1.  $E(p) = \pi \rightarrow p$  es insesgado.
2. Como  $V(X_i) = \sigma^2 = \pi(1 - \pi)$  y son independientes

$$V(p) = \frac{\sigma^2}{n} = \frac{\pi(1 - \pi)}{n}$$

3.  $V(p) = CCR(\pi) \rightarrow p$  es el estimador eficiente (en sentido CCR) para  $\pi$  en  $B(1, \pi)$

- **Nota:** Este resultado explica por qué la proporción muestral es el estimador 'natural' de  $\pi$ .

# Ejercicios rápidos C1 · Cramér–Rao

1. La CCR proporciona:

- a) un valor exacto de  $V(\hat{\theta})$
- b) un límite inferior para  $V(\hat{\theta})$
- c) un límite superior para el sesgo
- d) un test de hipótesis

2) Si un estimador insesgado alcanza la CCR, entonces:

- a) es consistente
- b) es suficiente
- c) es el eficiente (en sentido CCR)
- d) es robusto

3) En general, al aumentar  $n$  en una muestra i.i.d., suele ocurrir que:

- a)  $I_n(\theta)$  disminuye
- b) la CCR aumenta
- c)  $I_n(\theta)$  aumenta y la CCR disminuye
- d) la CCR no cambia

4) La CCR se aplica a:

- a) cualquier estimador, sesgado o no
- b) solo a estimadores robustos
- c) estimadores insesgados y bajo condiciones regulares
- d) solo a distribuciones normales

# Ejercicios rápidos C1 · Cramér–Rao

CORE

1. La CCR proporciona:

- a) un valor exacto de  $V(\hat{\theta})$
- b) un límite inferior para  $V(\hat{\theta})$  ✓
- c) un límite superior para el sesgo
- d) un test de hipótesis

2) Si un estimador insesgado alcanza la CCR, entonces:

- a) es consistente
- b) es suficiente
- c) es el eficiente (en sentido CCR) ✓
- d) es robusto

3) En general, al aumentar  $n$  en una muestra i.i.d., suele ocurrir que:

- a)  $I_n(\theta)$  disminuye
- b) la CCR aumenta
- c)  $I_n(\theta)$  aumenta y la CCR disminuye ✓
- d) la CCR no cambia

4) La CCR se aplica a:

- a) cualquier estimador, sesgado o no
- b) solo a estimadores robustos
- c) estimadores insesgados y bajo condiciones regulares ✓
- d) solo a distribuciones normales

# **Sección D.**

## **Suficiencia (y criterio de Fisher–Neyman)**


# Suficiencia: “resumen sin pérdida” (idea)

## Definición intuitiva, concisa:


- Un estadístico  $T(X)$  es **suficiente** para  $\theta$  si **contiene toda la información que aporta la muestra** sobre  $\theta$ .
- **Intuición:** una vez conoces  $T(X)$ , el resto de los datos **no aportan nada más** para inferir  $\theta$ .
- **Objetivo:** **reducir datos** sin perder información sobre el parámetro.

## ejemplos rápidos

- Si  $x_i \sim B(1, \pi)$ , un resumen natural es  $\sum x_i$  (número de éxitos).
- Si  $x_i \sim Poisson(\lambda)$ , un resumen natural es  $\sum x_i$  (número total de eventos).
- **Nota:** En muchos modelos, basta con sumas/medias para estimar el parámetro.



# Criterio de Fisher–Neyman



## Idea intuitiva:

- Para decidir si  $T(X)$  es suficiente, miramos si la verosimilitud  $L(\theta|x)$  se puede separar en:
  - una parte que depende de los datos solo a través de  $T(x)$  y de  $\theta$ .
  - y otra parte que depende de los datos, pero no de  $\theta$ .

Si se puede, entonces  $T(X)$  es suficiente

## Enunciado

$T(X)$  es suficiente para  $\theta$  si la función conjunta de la muestra se puede escribir como

$$f(x_1, \dots, x_n; \theta) = g(T(x), \theta) \cdot h(x)$$

Donde  $h(x)$  no depende de  $\theta$ .

## Cómo se usa

1. Escribe  $f(x_1, \dots, x_n; \theta)$
2. Reordena para aislar  $T(x)$ .
3. Identifica  $g(\cdot)$  y  $h(\cdot)$ .

# Fisher–Neyman en la Normal: intuición con fórmulas

CORE

## Modelo:

Sea un m.a.s.  $x_i \sim N(\mu, \sigma)$  v.a.i.i.d. con  $\sigma^2$  conocida

## Función conjunta (verosimilitud)

$$f(x_1, \dots, x_n; \mu) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x_i - \mu)^2}{2\sigma^2}\right]$$


## Reescribimos el exponente

$$\prod_{i=1}^n \exp\left[-\frac{(x_i - \mu)^2}{2\sigma^2}\right] = \exp\left[-\frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}\right] = \exp\left[-\frac{\sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2}{2\sigma^2}\right]$$

## Factorización (Fisher–Neyman)

$$f(x_1, \dots, x_n; \mu) = \underbrace{\exp\left(\frac{-n(\bar{x} - \mu)^2}{2\sigma^2}\right)}_{\text{depende de } \mu \text{ solo vía } \bar{x}} \cdot \underbrace{\left[ (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum (x_i - \bar{x})^2\right) \right]}_{h(x_1, \dots, x_n) \text{ no depende de } \mu}$$

**Conclusión:**  $\bar{x}$  es estadístico suficiente para  $\mu$




## Comentario

1. El término  $\sum_{i=1}^n (x_i - \bar{x})^2$  describe la forma interna de la muestra, pero **no cambia la verosimilitud relativa entre valores de  $\mu$** .
2. Por eso, una vez conocida  $\bar{x}$ , el resto de los datos es irrelevante para inferir  $\mu$ .

# Ejercicio corto · Suficiencia en Bernoulli $B(1, \pi)$

PLUS



## Pregunta

Sea  $x_1, \dots, x_n \sim B(1, \pi)$  v.a.i.i.d.

1. Escribe la función conjunta  $f(x_1, \dots, x_n; \pi)$
2. Factoriza para mostrar que

$$T(x_1, \dots, x_n) = \sum_{i=1}^n x_i$$

## Solución

1. Como  $f(x; \pi) = \pi^x (1 - \pi)^{1-x}$ ,

$$f(x_1, \dots, x_n; \pi) = \prod_{i=1}^n \pi^{x_i} (1 - \pi)^{1-x_i} = \pi^{\sum x_i} (1 - \pi)^{n - \sum x_i}$$

2. Identificamos:

$$g(T(x), \pi) = \pi^{\sum x_i} (1 - \pi)^{n - \sum x_i}, \quad h(x) = 1$$


Como  $h(x)$  no depende de  $\pi$ , por Fisher–Neyman:

$$T(X) = \sum_{i=1}^n x_i \text{ es suficiente para } \pi.$$

**Interpretación:** basta saber “número de éxitos” para inferir  $\pi$

# Ejercicio corto · Suficiencia en Poisson( $\lambda$ )

PLUS



## Pregunta

Sea  $x_1, \dots, x_n \sim \text{Poisson}(\lambda)$  con realización  $x_1, \dots, x_n$

1. Escribe la función conjunta  $f(x_1, \dots, x_n; \lambda)$
2. Factoriza para mostrar que

$$T(x_1, \dots, x_n) = \sum_{i=1}^n x_i$$

es suficiente para  $\lambda$ .

## Solución

1. Como  $f(x; \lambda) = e^{-\lambda} \frac{\lambda^x}{x!}$ ,

$$f(x_1, \dots, x_n; \lambda) = \prod_{i=1}^n e^{-\lambda} \frac{\lambda^{x_i}}{x_i!} = e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i} \prod_{i=1}^n \frac{1}{x_i!}$$

2. Identificamos:

$$f(x_1, \dots, x_n; \lambda) = g(T(x_1, \dots, x_n), \lambda) \cdot h(x_1, \dots, x_n)$$

$$g(T(x_1, \dots, x_n), \lambda) = e^{-n\lambda} \lambda^{T(x)}, \quad h(x_1, \dots, x_n) = \prod_{i=1}^n \frac{1}{x_i!}$$

Como  $h(x_1, \dots, x_n)$  no depende de  $\lambda$ , por Fisher–Neyman:

$$T(X) = \sum_{i=1}^n x_i \text{ es suficiente para } \lambda.$$

**Interpretación:** basta saber “número de ocurrencias” para inferir  $\lambda$ .

# Ejercicios rápidos · Suficiencia (test)

1.  $T(X)$  es suficiente para  $\theta$  si:

- a)  $T(X)$  es insesgado.
- b)  $T(X)$  tiene varianza mínima.
- c)  $f(X; \theta) = g(T(X), \theta)h(X)$ , con  $h(X)$  que no depende de  $\theta$ .
- d)  $T(X)$  es robusto.

2. En un m.a.s(n),  $x_i \sim B(1, \pi)$ , un estadístico suficiente para  $\pi$  es:

- a)  $T(X) = \max\{x_1, \dots, x_n\}$
- b)  $T(X) = \sum_{i=1}^n |x_i - \bar{x}|$
- c)  $T(X) = \sum x_i$
- d)  $T(X) = \sum (x_i^2 - \bar{x})$

3. En  $Poisson(\lambda)$ , un estadístico suficiente para  $\lambda$  es

- a)  $\sum x_i$
- b)  $\max x_i$
- c)  $\min x_i$
- d)  $\sum x_i^2$

4. En el criterio de Fisher–Neyman, la parte  $h(\mathbf{x})$  debe:

- a) depender de  $\theta$
- b) depender solo de  $T(X)$
- c) No depender de  $\theta$
- d) ser constante igual a 0

# Ejercicios rápidos · Suficiencia (test)

CORE

1.  $T(X)$  es suficiente para  $\theta$  si:

- a)  $T(X)$  es insesgado.
- b)  $T(X)$  tiene varianza mínima.
- c)  $f(X; \theta) = g(T(X), \theta)h(X)$ , con  $h(X)$  que no depende de  $\theta$ . ✓
- d)  $T(X)$  es robusto.

2. En un m.a.s(n),  $x_i \sim B(1, \pi)$ , un estadístico suficiente para  $\pi$  es:

- a)  $T(X) = \max\{x_1, \dots, x_n\}$
- b)  $T(X) = \sum_{i=1}^n |x_i - \bar{x}|$
- c)  $T(X) = \sum x_i$  ✓
- d)  $T(X) = \sum(x_i^2 - \bar{x})$

3. En  $Poisson(\lambda)$ , un estadístico suficiente para  $\lambda$  es

- a)  $\sum x_i$  ✓
- b)  $\max x_i$
- c)  $\min x_i$
- d)  $\sum x_i^2$


4. En el criterio de Fisher–Neyman, la parte  $h(\mathbf{x})$  debe:

- a) depender de  $\theta$
- b) depender solo de  $T(X)$
- c) No depender de  $\theta$  ✓
- d) ser constante igual a 0

## Respuestas

# Suficiencia: por qué importa (cierre)

CORE



## idea clave:

- **Suficiencia = resumen sin pérdida:**  $T(X)$  retiene toda la información de la muestra sobre el parámetro.
- **Ventaja práctica:** reduce el problema de trabajar con  $n$  datos a trabajar con **un resumen  $T(X)$**  (más simple).
- **Cómo se comprueba:** criterio de Fisher–Neyman:  $L(\theta|X) = g(T(X), \theta)h(X)$  con  $h(X)$  que no depende de  $\theta$ .

## Ejemplos

- $x_i \sim B(1, \pi)$ :  $T(X) = \sum x_i$  (número de éxitos) es suficiente para  $\pi$ .
- $x_i \sim Poisson(\lambda)$ :  $T(X) = \sum x_i$  (total de eventos) es suficiente para  $\lambda$ .

## Mini-frase final

Si  $T(X)$  es suficiente, no perdemos información sobre el parámetro al reemplazar la muestra por  $T(X)$ .

# Sección E. Invarianza y robustez

# Invarianza y robustez (dos propiedades prácticas)

CORE

## Invarianza

**Idea:** si tenemos un parámetro poblacional ( $\theta$ ) y construimos uno nuevo ( $\eta$ ) transformándolo con una función  $g$ :

$$\eta = g(\theta)$$


Entonces, si el estimador  $\hat{\theta}$  es invariante, el estimador del nuevo parámetro ( $\hat{\eta}$ ) es la transformación  $g$  aplicada al estimador del parámetro inicial :

$$\hat{\eta} = g(\hat{\theta})$$

### Ejemplo rápido:

Si  $\eta = 2\mu$  y  $\hat{\mu} = \bar{x}$ , entonces  $\hat{\eta} = 2\bar{x}$

## Robustez

- **Idea:** un estimador es robusto si **cambia poco ante valores atípicos** o pequeñas desviaciones del modelo.
- **Ejemplo rápido:** la **media es sensible a outliers**; la **mediana suele ser más robusta**.
- **Mini-test:** ¿Qué es más robusto ante un outlier extremo? Mediana 

# Cierre de tema

# Tema 3 · Propiedades y fórmulas mínimas

CORE

## Ideas clave

- Sesgo y Varianza explican el comportamiento de un estimador.
- $ECM(\hat{\theta}) = V(\hat{\theta}) + [\text{Sesgo}(\hat{\theta})]^2$

## Propiedades

- **Insesgadez (finita):**  $E(\hat{\theta}) = \theta$
- **Insesgadez asintótica:**  $E(\hat{\theta}) - \theta \rightarrow 0$
- **Consistencia:**  $\hat{\theta}_n \xrightarrow{p} \theta$
- **Eficiencia:** la menor  $V(\hat{\theta})$
- **Eficiencia relativa:**  $\min_{i=1, \dots, m} (V(\hat{\theta}_i))$
- **Suficiencia (idea):** resumen  $T(X)$  sin pérdida de información relevante.
- **Invarianza:**  $g(\theta) \rightarrow g(\hat{\theta})$
- **Robustez:** poca sensibilidad a *outliers*/supuestos.

## Formulas mínimas

- $Sesgo(\hat{\theta}) = E(\hat{\theta}) - \theta$
- $ECM(\hat{\theta}) = V(\hat{\theta}) + (\text{Sesgo}(\hat{\theta}))^2$
- $\hat{\theta}_n \xrightarrow{p} \theta$
- CCR
  - $V(\hat{\theta}) \geq \frac{1}{I_n(\theta)}$  ;  $V(\hat{\theta}) \geq \frac{(1+b'(\theta))^2}{I_n(\theta)}$
  - $I_n(\theta) = nI_1(\theta)$
  - $I_1(\theta) = E \left[ \left( \frac{\partial(\ln f(X;\theta))}{\partial \theta} \right)^2 \right]$

# Tema 3 · Propiedades de estadísticos básicos

CORE

Estadístico (parámetro)	Insesgadez	Consistencia	Eficiencia (CCR)	Suficiencia (idea)
$\bar{x}$ (para $\mu$ )	✓ $E(\bar{x}) = \mu$	✓ $V(\bar{x}) = \frac{\sigma^2}{n} \rightarrow 0 \Rightarrow \bar{x} \xrightarrow{p} \mu$	✓ Normal, $\sigma^2$ conocida	✓ Normal ( $\sigma^2$ conocida): $T = \sum X_i$
$S^2$ (para $\sigma^2$ )	✗ $E(S^2) = \frac{n-1}{n} \sigma^2$ ✓ $E(S^2) \xrightarrow{n \rightarrow \infty} \sigma^2$	✓ (con v.a.i.i.d.) $S^2 \xrightarrow{p} \sigma^2$	✗ Normal, $\mu$ desconocida: no alcanza CCR	✓ Normal: $T = (\sum x_i, \sum x_i^2)$
$S_1^2$ (para $\sigma^2$ )	✓ $E(S_1^2) = \sigma^2$	✓ (con i.i.d.) $S_1^2 \xrightarrow{p} \sigma^2$	✗ Normal, $\mu$ desconocida: no alcanza CCR	✓ Normal: $T = (\sum x_i, \sum x_i^2)$
$p = \bar{x}$ con $x_i \sim B(1, \pi)$ (para $\pi$ )	✓ $E(p) = \pi$	✓ $V(p) = \frac{\pi(1-\pi)}{n}$	✓ Bernoulli: $V(p) = \frac{1}{I_n(\pi)} = CCR(\pi)$	✓ Bernoulli: $T = \sum x_i$

**Invarianza:** estos estimadores son invariantes en el sentido habitual si  $\eta = g(\theta)$ , un estimador natural es  $\hat{\eta} = g(\hat{\theta})$ .

**Robustez (idea):**  $\bar{x}$ ,  $S^2$ ,  $S_1^2$  y  $p$  son **sensibles a valores atípicos**; para robustez se usan alternativas (p. ej., mediana, MAD, etc.).

**Nota:** “Eficiencia (CCR) y suficiencia se entienden en un **modelo concreto** (p.ej., Bernoulli para  $\pi$ , Normal para  $\mu, \sigma^2$ )”

# Bibliografía

- **Ruiz-Maya, L., Martín-Pliego López, F. J. (3.ª ed.). Fundamentos de Inferencia Estadística. Thomson–Paraninfo.**
- Casella, G., & Berger, R. L. (2002). *Statistical Inference* (2nd ed.). Duxbury/Thomson Learning.
- DeGroot, M. H., & Schervish, M. J. (2012). *Probability and Statistics* (4th ed.). Pearson.

Imágenes generadas con ChatGPT (OpenAI). Licencia del material: CC BY 4.0