



Lisbon School  
of Economics  
& Management  
Universidade de Lisboa

# Estatística II

Licenciatura em Gestão  
2.º Ano/1.º Semestre  
2023/2024

# Aulas Teóricas N.ºs 3 e 4 (Semana 2)

**Docente:** Elisabete Fernandes

**E-mail:** efernandes@iseg.ulisboa.pt



<https://doity.com.br/estatistica-aplicada-a-nutricao>



<https://basiccode.com.br/produto/informatica-basica/>

# Conteúdos Programáticos

Aulas Teóricas  
(Semanas 1 a 5)

- **Capítulo 1:** Estimação

Aulas Teóricas  
(Semanas 5 a 7)

- **Capítulo 2:** Testes de Hipóteses

Aulas Teóricas  
(Semanas 7 a 9)

- **Capítulo 3:** Modelo de Regressão Linear

Aulas Teóricas  
(Semanas 10 a 13)

- **Capítulo 4:** Complementos ao Modelo de Regressão Linear

**Material didático:** Exercícios do Livro Murteira et al (2015), Formulário e Tabelas Estatísticas

**Bibliografia:** B. Murteira, C. Silva Ribeiro, J. Andrade e Silva, C. Pimenta e F. Pimenta; *Introdução à Estatística*, 2ª ed., Escolar Editora, 2015.

<https://cas.iseg.ulisboa.pt>

## 1. Estimação

- a. Introdução
- b. Métodos dos momentos
- c. Método da máxima verosimilhança
- d. Propriedade dos estimadores por pontos
- e. Estimação por intervalos para populações normais
- f. Estimação por intervalos para populações não normais (grandes amostras)

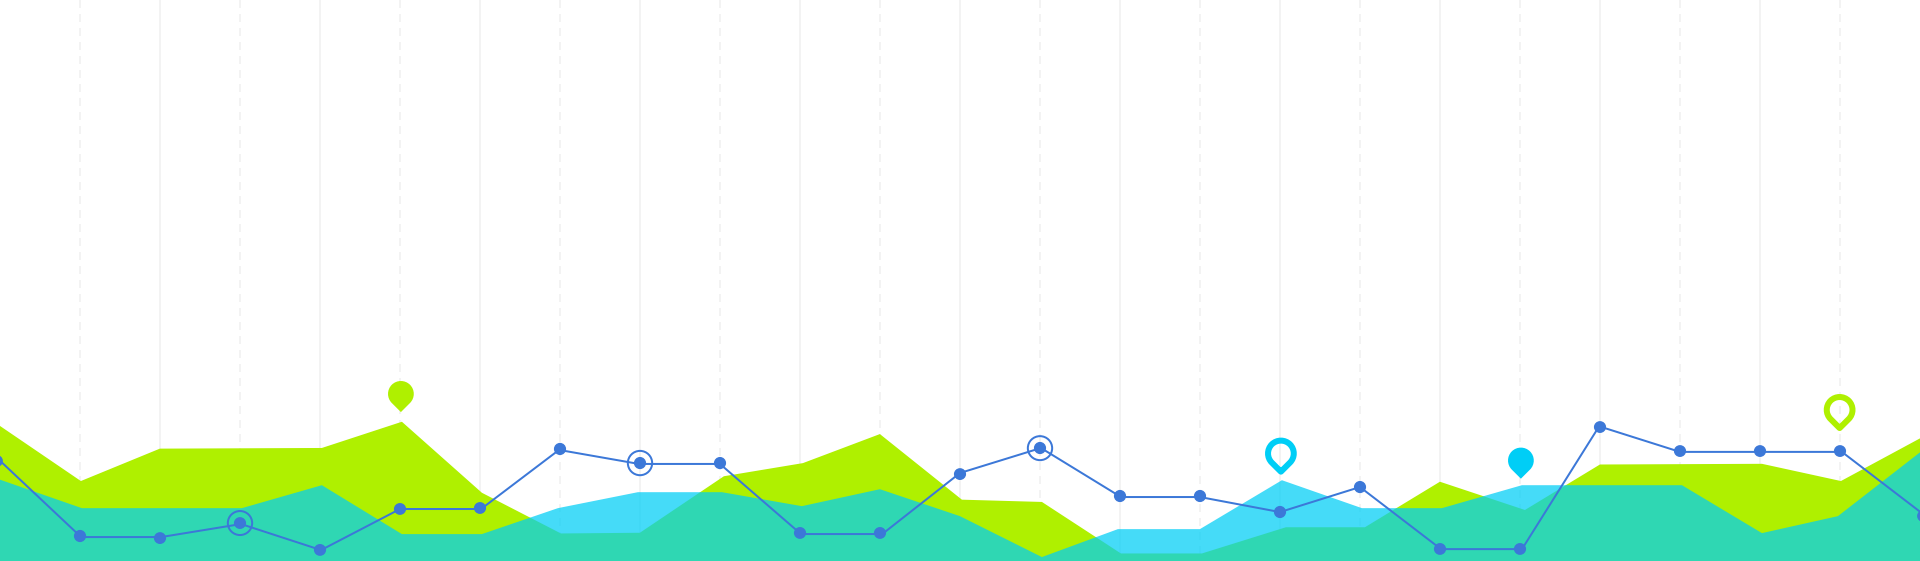
2ª semana (26/9 e 28/9)

T03 - Estimação - Método da Máxima Verosimilhança

Introdução. Apresentação do método. Exemplos

T04 - Propriedades dos Estimadores

Introdução. Estimadores centrados. Estimadores eficientes (introdução). Exemplos



# Método da Máxima Verosimilhança

Estimadores

1

# Métodos de Estimação

Até aqui falámos em **estimadores** e nas propriedades que devem possuir. Interessa ter procedimentos que construam estimadores com boas propriedades.

Vamos então falar dos **principais métodos de estimação paramétrica**.

Dos **métodos de estimação paramétrica** vamos referir:

o **Método dos momentos** e

o **Método da Máxima verosimilhança**

# Função de Verosimilhança

Seja  $X$  uma v.a. cuja distribuição depende de um **parâmetro**  $\theta$ , desconhecido, e  $(X_1, \dots, X_n)$  uma amostra aleatória. Seja  $(x_1, \dots, x_n)$  a amostra observada.

## Definição

Chama-se **verossimilhança da amostra** e representa-se por  $\mathcal{L}(\theta|x_1, x_2, \dots, x_n)$  a

$$f(x_1, \dots, x_n|\theta) = \prod_{i=1}^n f(x_i|\theta) \quad \text{caso contínuo}$$

$$P(X_1 = x_1, \dots, X_n = x_n|\theta) = \prod_{i=1}^n P(X_i = x_i|\theta) \quad \text{caso discreto}$$

# Método da Máxima Verosimilhança

O **método da máxima verosimilhança**, proposto por Fisher em 1922 e desenvolvido em 1925 consiste em escolher como **estimativa de  $\theta$**  o valor que **maximiza a verosimilhança**  $\mathcal{L}(\theta | \mathbf{x}_1, \dots, \mathbf{x}_n)$ , face a uma amostra observada  $(x_1, \dots, x_n)$ .



# Função de Log-Verossimilhança

Em muitas situações as funções de verossimilhança satisfazem condições que permitem que o valor para o qual a verossimilhança é máxima seja obtido por derivação.

Porém, e como a função logarítmica é monótona, regra geral é mais cómodo trabalhar com a função **log-verossimilhança**,

$$\log \mathcal{L}(\theta|\underline{x})$$

# Método da Máxima Verosimilhança (MMV)

Então, no caso de existirem derivadas (e para um único parâmetro  $\theta$ ), o valor do maximizante é obtido de modo que:

$$\frac{d \log \mathcal{L}}{d\theta} = 0 \quad \text{e} \quad \frac{d^2 \log \mathcal{L}}{d\theta^2} < 0$$

Note-se que 
$$\frac{d \log \mathcal{L}}{d\theta} = \sum_{i=1}^n \frac{d \log f(x_i|\theta)}{d\theta}$$

A solução,  $\hat{\theta}(x_1, \dots, x_n)$  é a **estimativa de máxima verosimilhança**, que é uma realização da v.a.  $\hat{\Theta} = \hat{\Theta}(X_1, \dots, X_n)$ .

## MMV: Exemplo 1

Considere-se  $X \cap P(\lambda)$  e a amostra  $(0, 0, 2, 5, 3, 1)$ .  
Determine uma estimativa de máxima verosimilhança  
de  $\lambda$ ?



# MMV: Exemplo 1

Exemplo

$X \sim \text{Poi}(\lambda)$

$(0, 0, 2, 5, 3, 1)$

$\text{EMV}(\lambda)$  [ estimativa de máxima verosimilhança de  $\lambda$  com base nestes dados ]

milhance de  $\lambda$  com base nestes dados )

Passo 2 :  $\alpha(\lambda; 0, 0, 2, 5, 3, 1) =$

$$= \prod_{i=1}^6 \frac{e^{-\lambda} \lambda^{x_i}}{x_i!} = \left[ \frac{e^{-\lambda} \lambda^0}{0!} \right] \left[ \frac{e^{-\lambda} \lambda^0}{0!} \right] \left[ \frac{e^{-\lambda} \lambda^2}{2!} \right]$$

$$\left[ \frac{e^{-\lambda} \lambda^5}{5!} \right] \left[ \frac{e^{-\lambda} \lambda^3}{3!} \right] \left[ \frac{e^{-\lambda} \lambda^1}{1!} \right]$$

$$= e^{-6\lambda} \frac{\lambda^4}{2! 5! 3! 1!} \equiv \theta(\lambda)$$

# MMV: Exemplo 1

Pessoa 2  $g'(\lambda) = \frac{-6 e^{-6\lambda} \lambda^{11} + 11 e^{-6\lambda} \lambda^{10}}{2! 3! 5! 1!}$

$$= 0 \Leftrightarrow -6\lambda + 11 = 0 \Leftrightarrow \lambda = \frac{11}{6}$$

$$g''(\lambda) = 36 e^{-6\lambda} \dots \Big|_{\lambda = \frac{11}{6}} < 0$$

$$\text{emv}(\lambda) = \frac{11}{6}$$

Pessoa 2\*: Em vez de maximizar  $g(\lambda)$

vamos maximizar  $\log g(\lambda)$

$$g(\lambda) = \frac{e^{-6\lambda} \lambda^{11}}{0! 2! 5! 3! 1!}$$

$$\ln g(\lambda) = -6\lambda + 11 \log \lambda - \log(\dots)$$

$$[\ln g(\lambda)]' = -6 + \frac{11}{\lambda}$$

$$[\ln g(\lambda)]'' = -\frac{11}{\lambda^2} < 0, \forall \lambda$$

$$\text{emv: } -6 + \frac{11}{\lambda} = 0 \Leftrightarrow \boxed{\lambda = \frac{11}{6}}$$

1.  $y = u^n \Rightarrow y' = nu^{n-1}u'$ ;

2.  $y = c \Rightarrow y' = 0$ , onde  $k$  é uma constante real;

3.  $y = uv \Rightarrow y' = u'v + v'u$

4.  $y = \frac{u}{v} \Rightarrow y' = \frac{u'v - v'u}{v^2}$

5.  $y = a^u \Rightarrow y' = a^u(\ln a)u'$ , ( $a > 0, a \neq 1$ )

6.  $y = e^u \Rightarrow y' = e^u u'$

7.  $y = \log_a u \Rightarrow y' = \frac{u'}{u} \log_a e$

8.  $y = \ln u \Rightarrow y' = \frac{1}{u} u'$

9.  $y = u^v \Rightarrow y' = vu^{v-1}u' + u^v(\ln u)v'$

10.  $y = \sin u \Rightarrow y' = u' \cos u$

11.  $y = \cos u \Rightarrow y' = -u' \sin u$

12.  $y = \tan u \Rightarrow y' = u' \sec^2 u$ , desde que  $x \neq (2n+1)\frac{\pi}{2}, n \in \mathbb{Z}$ ;

13.  $y = \cot u \Rightarrow y' = -u' \csc^2 u$ , desde que  $x \neq n\pi, n \in \mathbb{Z}$ ;

## MMV: Exemplo 2

Considere-se a v.a.  $X \cap \text{Exp}(\mu)$  e a amostra  $(1.2, 0.5, 3)$ .  
Determine uma estimativa de máxima verosimilhança de  $\mu$ ?



# MMV: Exemplo 2

Exemplo 2:  $X \sim \text{Exp}(\mu)$   $f_X(x) = \mu e^{-\mu x}$ ,  $x > 0$

amostras: (1.2; 0.5; 3)

$$\text{e.m.v.}(\mu) = \hat{\mu} = \frac{3}{1.2 + 0.5 + 3}$$

Como  $X$  é v.c. contínua:

$$\begin{aligned} \bullet d(\mu; x_1, x_2, x_3) &= \prod_{i=1}^3 \mu e^{-\mu x_i} = \\ &= \mu^3 e^{-\mu \sum x_i} = \mu^3 e^{-\mu(1.2 + 0.5 + 3)} \end{aligned}$$

$$\bullet \ln g(\mu) = 3 \ln \mu - 4.7 \mu$$

$$[\ln g(\mu)]' = \frac{3}{\mu} - 4.7 = 0 \Leftrightarrow \mu = \frac{3}{4.7}$$

$$[\ln g(\mu)]'' = -\frac{3}{\mu^2} < 0, \forall \mu$$

$$\Rightarrow \text{e.m.v.}(\mu) = \hat{\mu} = \frac{3}{4.7}$$

# Propriedade Fundamental dos EMV: Invariância

Propriedade fundamental dos EMV: Invariância

$$EMV(h(\theta)) = h(EMV(\theta))$$

Exemplo:

$$EMV(\lambda) = \bar{x}$$

$$EMV(\ln \lambda) = \ln(EMV(\lambda)) = \ln \bar{x}$$





# Método da Máxima Verosimilhança: Exercícios

Estimadores

# 2

3. Considere uma população com distribuição de Bernoulli, com parâmetro  $p$ , com  $0 < p < 1$ .
- Derive o estimador de máxima verosimilhança para o parâmetro  $p$ .
  - Foi obtida uma amostra de dimensão  $n = 3$ , cujos valores observados foram  $(1, 1, 0)$ .
    - Esboce o gráfico da função de verosimilhança e interprete-o.
    - Forneça uma estimativa para  $p$  com base no método da máxima verosimilhança.



## Exercício 2 a): Estimação de Máxima Verosimilhança

a) Função de probabilidade (f. p.):

$$f(x; p) = p^x (1 - p)^{1-x}, \quad x = 0, 1, \text{ com } 0 < p < 1.$$

Função de verosimilhança:

$$\mathcal{L}(p) = \prod_{i=1}^n f(x_i; p) = \prod_{i=1}^n p^{x_i} (1 - p)^{1-x_i} = p^{\sum_{i=1}^n x_i} (1 - p)^{n - \sum_{i=1}^n x_i}.$$

Logaritmo da função de verosimilhança:

$$\ln(\mathcal{L}(p)) = \sum_{i=1}^n x_i \ln p + \left( n - \sum_{i=1}^n x_i \right) \ln(1 - p).$$

## Exercício 2 a): Estimação de Máxima Verosimilhança

Condição de 1ª ordem:

$$\begin{aligned}\frac{\partial \ln(\mathcal{L}(p))}{\partial p} = 0 &\Leftrightarrow \sum_{i=1}^n x_i \left(\frac{1}{p}\right) + \left(n - \sum_{i=1}^n x_i\right) \left(\frac{-1}{1-p}\right) = 0 \Leftrightarrow (1-p) \sum_{i=1}^n x_i - p \left(n - \sum_{i=1}^n x_i\right) = 0 \\ &\Leftrightarrow \sum_{i=1}^n x_i - pn = 0 \Leftrightarrow p = \sum_{i=1}^n \frac{x_i}{n}.\end{aligned}$$

Condição de 2ª ordem:

$$\frac{\partial^2 \ln L(p; x)}{\partial p^2} = -\frac{\sum_{i=1}^n x_i}{p^2} + \frac{(n - \sum_{i=1}^n x_i)(-1)}{(1-p)^2} = -\frac{\sum_{i=1}^n x_i}{p^2} - \frac{(n - \sum_{i=1}^n x_i)}{(1-p)^2} < 0,$$

pois  $x_i \geq 0$ ,  $p^2 > 0$ ,  $n > 0$ ,  $(1-p)^2 > 0$  e  $n \geq \sum_{i=1}^n x_i$  pois  $x_i = 0$  ou  $1$ .


Portanto, o estimador de máxima verosimilhança é:

$$\hat{p} = \sum_{i=1}^n \frac{X_i}{n}.$$

## Exercício 2 b) i e ii: Estimação de Máxima Verosimilhança

b) i) Substituindo em  $\mathcal{L}(p)$ ,  $(x_1, x_2, x_3)$  pelos valores observados na amostra,  $(1, 1, 0)$ , obtemos,

$$\mathcal{L}(p) = p^2(1 - p).$$



A função de verosimilhança atinge o seu valor máximo quando o  $p$  se situa perto de 0,65, sendo este o valor de  $p$  mais provável que deu origem à observação desta amostra.

ii)  $\hat{p} = \frac{2}{3} = 0,6667$

Exercício Suplementar que não consta do livro Murteira et al (2015)

2. Seja  $X_1, X_2, \dots, X_n$  uma a. a. de uma distribuição Normal,  $X \sim N(\mu; \sigma)$ . Estime os parâmetros  $\mu$  e  $\sigma$  pelo método:

b) Da máxima verosimilhança.

[ProbabilidadesEstatistica 2019 \(uevora.pt\)](http://uevora.pt)



## Exercício 2: Estimação de Máxima Verosimilhança

b) Função densidade de probabilidade (f. d. p.):

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad -\infty < \mu < +\infty, \quad \sigma > 0.$$

Função de verosimilhança:

$$\begin{aligned} \mathcal{L}(\mu, \sigma^2) &= \prod_{i=1}^n f(x_i; \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x_i-\mu}{\sigma}\right)^2} = \frac{1}{(\sqrt{2\pi\sigma^2})^n} e^{-\frac{1}{2\sigma^2}\sum_{i=1}^n (x_i-\mu)^2} \\ &= \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} e^{-\frac{1}{2\sigma^2}\sum_{i=1}^n (x_i-\mu)^2}. \end{aligned}$$

Logaritmo da função de verosimilhança:

$$\ln(\mathcal{L}(\mu, \sigma^2)) = -\frac{n}{2}(\ln(2) + \ln(\pi) + \ln(\sigma^2)) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2.$$

## Exercício 2: Estimação de Máxima Verosimilhança

Condições de 1ª ordem:

$$\begin{aligned} \begin{cases} \frac{\partial \ln L(\mu, \sigma^2)}{\partial \mu} = 0 \\ \frac{\partial \ln L(\mu, \sigma^2)}{\partial \sigma^2} = 0 \end{cases} &\Leftrightarrow \begin{cases} -\frac{1}{2\sigma^2} \left( -2 \sum_{i=1}^n x_i + 2n\mu \right) = 0 \\ -\frac{n}{2\sigma^2} + \sum_{i=1}^n (x_i - \mu)^2 \frac{2}{4\sigma^4} = 0 \end{cases} \Leftrightarrow \begin{cases} \sum_{i=1}^n x_i - n\mu = 0 \\ -n\sigma^2 + \sum_{i=1}^n (x_i - \mu)^2 = 0 \end{cases} \\ &\Leftrightarrow \begin{cases} \mu = \sum_{i=1}^n \frac{x_i}{n} \\ \sigma^2 = \sum_{i=1}^n \frac{(x_i - \mu)^2}{n} \end{cases} \Leftrightarrow \begin{cases} \mu = \bar{x} \\ \sigma^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n} \end{cases} \Leftrightarrow \begin{cases} \mu = \bar{x} \\ \sigma^2 = \left( \frac{n-1}{n} \right) s^2 \end{cases} \end{aligned}$$



## Exercício 2: Estimação de Máxima Verosimilhança

Condições de 2ª ordem:

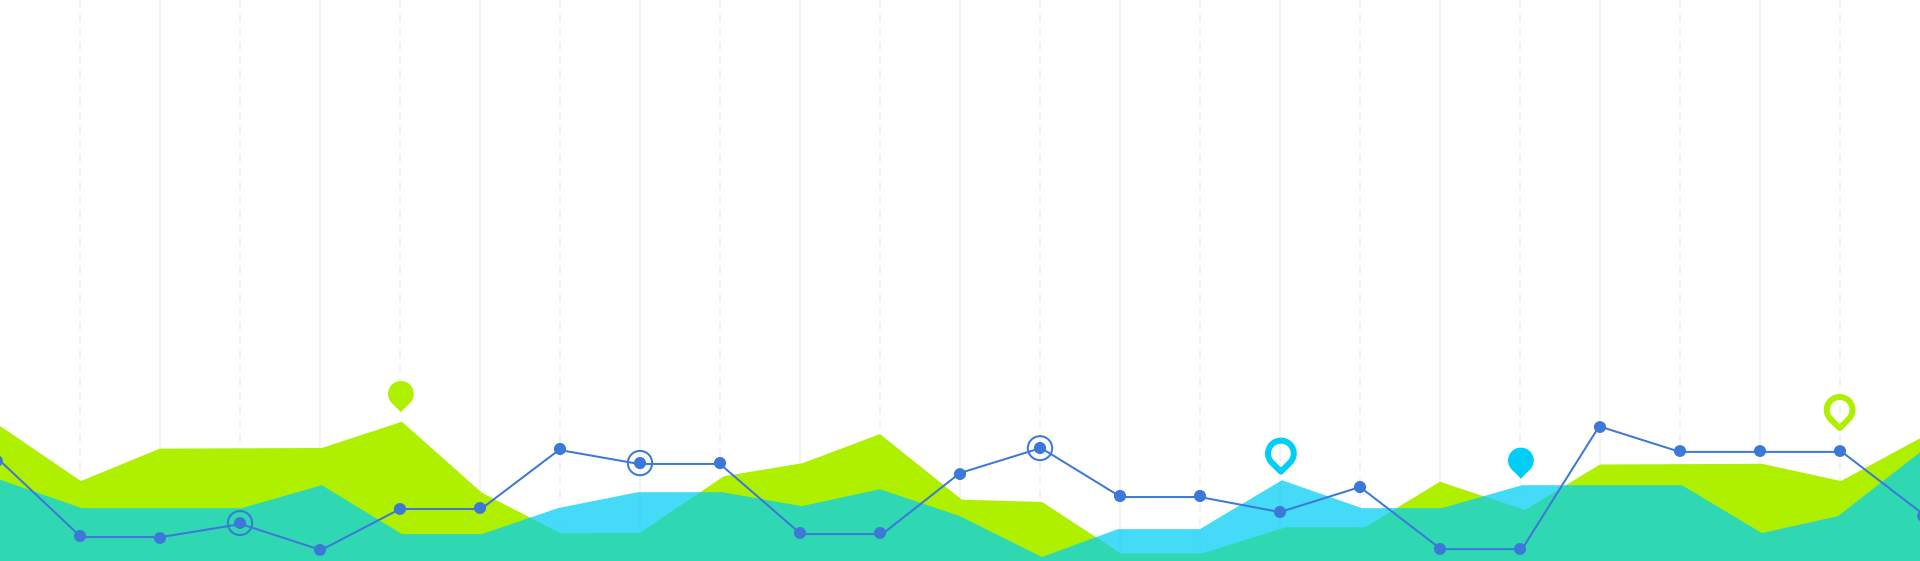
$$\begin{cases} \frac{\partial^2 \ln L(\mu, \sigma^2)}{\partial \mu^2} = -\frac{1}{2\sigma^2} 2n < 0 \\ \frac{\partial^2 \ln L(\mu, \sigma^2)}{\partial \sigma^4} = \frac{n}{2} \frac{1}{\sigma^4} - \sum_{i=1}^n \frac{(x_i - \mu)^2}{\sigma^6} < 0 \end{cases}'$$

pois  $n > 0, \sigma^2 > 0, \sum_{i=1}^n \frac{(x_i - \mu)^2}{\sigma^6} > \frac{n}{2} \frac{1}{\sigma^4}$ .

## Exercício 2: Estimação de Máxima Verosimilhança

Portanto, os estimadores de máxima verosimilhança obtidos foram:

$$\left\{ \begin{array}{l} \hat{\mu} = \bar{X} = \sum_{i=1}^n \frac{X_i}{n} \\ \hat{\sigma}^2 = \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{n} = \frac{n-1}{n} S^2 \end{array} \right.$$



# Propriedades dos Estimadores

Estimador Centrado, Consistente e Eficiente

# 3

# Principais Propriedades dos Estimadores

Principais propriedades desejáveis nos estimadores:

- *Não enviesamento* – em termos médios, o estimador atinge o valor real do parâmetro;
- *Eficiência* – o estimador é mais eficiente quanto menor for a sua variância;
- 
- *Consistência* – para  $n$  grande, o estimador deve ser aproximadamente igual ao parâmetro.

# Estimador Centrado ou não Enviesado

**Definição:** Um estimador  $\hat{\theta}$  diz-se **não enviesado** ou **centrado** do parâmetro  $\theta$  se:

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

**Definição:** Seja  $\hat{\theta}$  um estimador do parâmetro  $\theta$ . O **enviesamento** (*Env*) de  $\hat{\theta}$  é dado por:

Viés ou Bias  $\nearrow$   $Env(\hat{\theta}) = E(\hat{\theta}) - \theta.$

[ProbabilidadesEstadistica2019.pdf](#)

# Estimador Eficiente

**Definição:** Sejam  $\hat{\theta}$  e  $\tilde{\theta}$  dois estimadores centrados do parâmetro  $\theta$ , baseados no mesmo número de observações. Então:

- $\hat{\theta}$  diz-se **mais eficiente** do que  $\tilde{\theta}$  se:  $Var(\hat{\theta}) < Var(\tilde{\theta})$
- A **eficiência relativa** do primeiro estimador relativamente ao segundo é dada por:

$$\text{Eficiência relativa} = \frac{Var(\hat{\theta})}{Var(\tilde{\theta})}$$

$\hat{\theta}$  é um estimador eficiente de  $\theta$  se ele satisfizer as seguintes condições: (i)  $\hat{\theta}$  é não viesado; (ii)  $Var(\hat{\theta}) \leq Var(\tilde{\theta})$ , onde  $\tilde{\theta}$  é qualquer outro estimador não viesado de  $\theta$ .

Para comparar dois estimadores enviesados utiliza-se o critério do erro quadrático médio. [Microsoft Word - PROPRIEDADES DOS ESTIMADORES.docx \(usp.br\)](#)

**Definição:** Seja  $\hat{\theta}$  um estimador do parâmetro  $\theta$ . O **erro quadrático médio** (EQM) de  $\hat{\theta}$  é dado por:

$$EQM(\hat{\theta}) = Var(\hat{\theta}) + (Env(\hat{\theta}))^2$$

*Observação:* Se  $\hat{\theta}$  um estimador centrado para o parâmetro  $\theta$ , então  $Env(\hat{\theta}) = 0$  e, por conseguinte,  $EQM(\hat{\theta}) = Var(\hat{\theta})$ .

estimador viesado jamais será eficiente, por menor que seja o viés.

**Definição:** Sejam  $\hat{\theta}$  e  $\tilde{\theta}$  dois estimadores. Diz-se que  $\hat{\theta}$  é “melhor” que  $\tilde{\theta}$  se:

$$EQM(\hat{\theta}) < EQM(\tilde{\theta}).$$

[Microsoft Word - PROPRIEDADES DOS ESTIMADORES.docx \(usp.br\)](#)  
[ProbabilidadesEstadistica2019.pdf](#)

# Erro Quadrático Médio (EQM)

## 3. Erro quadrático médio

Chama-se **erro quadrático médio** do estimador  $\Theta^*$  a **EQM**  $(\Theta^*) = E[(\Theta^* - \theta)^2]$ .

Esta propriedade é um dos critérios mais usados para comparar estimadores.

É muito fácil mostrar que

$$EQM(\Theta^*) = Var[\Theta^*] + [b_{\theta}(\Theta^*)]^2$$

Se  $\Theta^*$  é um **estimador centrado** de um parâmetro então o **erro quadrático médio**  $\equiv$  **variância**, i.e.

$$E[(\Theta^* - \theta)^2] = Var(\Theta^*)$$

# Exatidão vs Precisão

O termo **exatidão (accuracy)** refere-se à proximidade de uma medição ou estimativa ao verdadeiro valor.

O termo **precisão ou variância (precision)** refere-se ao “grau de concordância numa sucessão de medições”.



## Accuracy & Precision



Accurate  
but , not precise



Precise  
but , not accurate



Accurate  
and Precise



# Eficiência Relativa vs Eficiência Absoluta

Observações:

- A eficiência exige a existência de momentos de segunda ordem dos estimadores.
- A definição de eficiência apresenta dois conceitos diferentes:
  - O primeiro estabelece uma relação entre dois estimadores centrados para  $\theta$ , sendo portanto uma **eficiência relativa**.
  - O segundo é um conceito de **eficiência absoluta** na classe dos estimadores centrados para  $\theta$ .
- Para obter estimadores mais eficientes recorre-se à **desigualdade de Fréchet-Cramér-Rao**.

**Teorema 7.1** – Seja  $(X_1, X_2, \dots, X_n)$  uma amostra casual de população com função densidade (função probabilidade)  $f(x|\theta)$ , satisfazendo certas condições de regularidade, e seja  $T = T(X_1, X_2, \dots, X_n)$  um estimador centrado de  $\theta$ . Então,

$$\text{Var}(T) \geq \frac{1}{n\mathfrak{I}(\theta)},$$

onde,

Slides Andrade e Silva

$$\mathfrak{I}(\theta) = E\left\{\left[\frac{\partial \ln f(X|\theta)}{\partial \theta}\right]^2\right\} = -E\left\{\left[\frac{\partial^2 \ln f(X|\theta)}{\partial \theta^2}\right]\right\} \text{ (quantidade de informação de Fisher)}$$

# Estimador Centrado de Variância Mínima

Conhecido o limite inferior dado pela desigualdade de Fréchet-Cramér-Rao, compara-se a variância do estimador centrado em análise com este limite:

- caso sejam iguais → não existe nenhum outro estimador centrado de variância inferior sendo o estimador em análise o mais eficiente;
- caso contrário → o quociente,  $[n\mathfrak{I}(\theta)]^{-1} / \text{Var}(T)$ , fornece uma indicação sobre a eficiência relativa do estimador  $T$  face ao hipotético estimador de variância igual ao limite inferior da desigualdade.

# Estimador Convergente ou Consistente

**Definição:** Um estimador  $\hat{\theta}$  diz-se **consistente** quando para qualquer valor positivo  $\delta$ , se verifica a condição:

$$\lim_{n \rightarrow \infty} P[|\hat{\theta} - \theta| < \delta] = 1.$$

**Teorema:** As condições:

- $\lim_{n \rightarrow +\infty} E(\hat{\theta}) = \theta;$
- $\lim_{n \rightarrow +\infty} Var(\hat{\theta}) = 0.$

são suficientes para que  $\hat{\theta}$  seja estimador **consistente**.

# Estimador dos Momentos vs EMV

## Propriedades dos estimadores obtidos pelo método dos momentos

- Em condições bastante gerais, são consistentes e possuem distribuição aproximadamente normal quando a dimensão da amostra é muito grande (distribuição assintótica).

## Propriedades dos estimadores obtidos pelo método da máxima verosimilhança

- Os estimadores de máxima verosimilhança não são necessariamente centrados.
- Em condições muito gerais eles são consistentes.
- Demonstra-se que, se existir estimador mais eficiente (na óptica do teorema de Fréchet-Cramér-Rao) ele é solução única da equação  $dL/d\theta = 0$  e portanto estimador de máxima verosimilhança.
- Verificadas certas condições de regularidade, os estimadores da máxima verosimilhança seguem assintoticamente uma distribuição normal. Caso haja apenas 1 parâmetro desconhecido, tem-se

$$\sqrt{n\mathcal{I}(\theta)}(\hat{\theta} - \theta) \overset{a}{\sim} N(0,1)$$

# Obrigada!

Questões?

