



Lisbon School  
of Economics  
& Management  
Universidade de Lisboa

# Estatística II

Licenciatura em Gestão do Desporto  
2.º Ano/2.º Semestre  
2023/2024

# Aulas Teórico-Práticas N.ºs 10 e 11 (Semana 6)

**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 Teórico-Práticas (Semanas 1 a 5)

- **Capítulo 1:** Revisões e Distribuições de Amostragem

## Aulas Teórico-Práticas (Semanas 5 a 7)

- **Capítulo 2:** Estimação

## Aulas Teórico-Práticas (Semanas 7 a 9)

- **Capítulo 3:** Testes de Hipóteses


## Aulas Teórico-Práticas (Semanas 10 a 13)

- **Capítulo 4:** Modelo de Regressão Linear Múltipla

**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>



# Método dos Momentos

Estimadores

1

# Métodos de Estimação

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

# Métodos dos Momentos

Introduzido por Karl Pearson no início do século XX, foi o primeiro método de estimação a ser apresentado e que tem uma filosofia muito simples.

O método consiste em:

– considerar como estimadores dos parâmetros desconhecidos as soluções das equações que se obtêm igualando os momentos teóricos aos momentos empíricos.

Momentos empíricos ou  
Momentos amostrais

Momentos teóricos ou  
Momentos populacionais

É um método de aplicação geral, tendo como única condição que a distribuição tenha um número suficiente de momentos (teóricos).

[modulo1\\_aula3\\_4\\_Estimacao.pdf](#)

# Métodos dos Momentos

Sejam  $\theta_1, \dots, \theta_k$  parâmetros desconhecidos de uma v.a.  $X$ .  
O método dos momentos consiste em igualar momentos teóricos e momentos empíricos, i.e.,

$$E[X] = m'_1 \quad \text{c/} \quad m'_1 = \frac{1}{n} \sum_{i=1}^n x_i$$

$$E[X^2] = m'_2 \quad \text{c/} \quad m'_2 = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$\vdots$

$$E[X^k] = m'_k \quad \text{c/} \quad m'_k = \frac{1}{n} \sum_{i=1}^n x_i^k$$

$m'_k = \frac{1}{n} \sum_{i=1}^n x_i^k$  são os chamados **momentos empíricos**, calculados à custa da amostra  $(x_1, \dots, x_n)$ .

Aquelas igualdades dão-nos **estimativas** que são concretização dos **estimadores** com as expressões correspondentes.

# Métodos dos Momentos: Exemplo

Considere-se  $X \cap N(\mu, \sigma^2)$ . Quais são os estimadores dos momentos de  $\mu$  e  $\sigma^2$ ?





# Métodos dos Momentos: Exemplo

## Exemplo

Consideremos  $X \sim \mathcal{N}(\mu, \sigma)$ . Quais os **estimadores** de momentos de  $\mu$  e  $\sigma^2$ ?

Tem-se :

$$E[X] = \mu \quad \text{e} \quad M'_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$
$$E[X^2] = \sigma^2 + \mu^2 \quad \text{e} \quad M'_2 = \frac{1}{n} \sum_{i=1}^n X_i^2$$

donde

$$\mu^* = \bar{X}$$
$$(\sigma^2)^* = \frac{1}{n} \sum_{i=1}^n X_i^2 - \mu^{*2} \Rightarrow (\sigma^2)^* = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

$$\begin{cases} \mu = \frac{1}{n} \sum_{i=1}^n x_i \\ \sigma^2 + \mu^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 \end{cases} \Leftrightarrow \begin{cases} \mu = \bar{x} \\ \sigma^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \end{cases}$$

[modul01\\_aula3\\_4\\_Estimação.pdf](#)

Portanto, os estimadores são:

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

Variância corrigida ( $s^2$ )


$$\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}$$

# Métodos dos Momentos

Os cálculos não são complicados, mas no cálculo dos momentos empíricos aparecem potências de expoente elevado quando há muitos parâmetros, conduzindo a estimativas instáveis.

Por isso, **como regra prática deve evitar-se recorrer ao método dos momentos para mais de quatro parâmetros.**

**Nota:** Os estimadores obtidos pelo método dos momentos são menos eficientes do que os estimadores de máxima verosimilhança, que passamos já a apresentar.



# Método dos Momentos: Exercícios

Estimadores

# 2

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

**Exercício 1:** Suponha que  $X_1, X_2, \dots, X_n$  é uma a.a. proveniente de uma distribuição exponencial com o parâmetro  $\lambda$ . Determine o estimador dos momentos de  $\lambda$ .



# Exercício 1: Estimador dos Momentos

$$f(x) = \lambda e^{-\lambda x}, 0 \leq x < \infty$$

$$\mu = E(X) = \frac{1}{\lambda}$$

1º Momento da Amostra:  $\frac{\sum_{i=1}^n X_i}{n} = \bar{X}$

1º Momento da População:  $E[X] = \frac{1}{\lambda}$

Método dos Momentos:  $E[X] = \bar{X}$

$$\frac{1}{\lambda} = \bar{X}$$

MM

$$\hat{\lambda}_{MM} = \frac{1}{\bar{X}}$$

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

**Exercício 2:** Seja  $X_1, X_2, \dots, X_n$  uma a.a. que segue uma v.a. com função densidade de probabilidade dada por

$$f(x|\alpha) = (\alpha + 1) \cdot x^\alpha I_{(0,1)}(x) \quad \alpha > 0.$$

Encontre um estimador para  $\alpha$  utilizando o método dos momentos.



## Exercício 2: Estimador dos Momentos

Solução pelo método de momentos:  $\mu_2' = m_2$

$$\mu_1' = E(X) = \int_0^1 x \cdot f(x) dx = (\alpha+1) \cdot \int_0^1 x^{\alpha+1} dx = (\alpha+1) \cdot \frac{x^{\alpha+2}}{\alpha+2} \Big|_0^1$$

$$\text{Logo, } \mu_2' = \frac{\alpha+1}{\alpha+2}$$

Tabela 1.1: Tabela de Primitivas Elementares

$f$	$Pf=F$
$c, c \in \mathbb{R}$	$c x$
$x^\alpha \ (\alpha \neq -1)$	$\frac{x^{\alpha+1}}{\alpha+1}$
$\frac{1}{x}$	$\log x $
$e^x$	$e^x$
$\cos x$	$\sin x$
$\sin x$	$-\cos x$
$\sec^2 x$	$\operatorname{tg} x$
$\operatorname{cosec}^2 x$	$-\operatorname{cotg} x$
$\frac{1}{1+x^2}$	$\operatorname{arctg} x$
$\frac{1}{\sqrt{1-x^2}}$	$\operatorname{arcsin} x$
$\cosh x$	$\sinh x$
$\sinh x$	$\cosh x$

## Exercício 2: Estimador dos Momentos

Assim,

$$m_1 = \mu'_1 \implies \frac{\hat{\alpha} + 1}{\hat{\alpha} + 2} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

Segue que,


$$\begin{aligned}\hat{\alpha} + 1 &= (\hat{\alpha} + 2) \cdot \bar{X} \\ \hat{\alpha} + 1 &= \hat{\alpha} \bar{X} + 2 \bar{X} \\ \hat{\alpha} (1 - \bar{X}) &= 2 \bar{X} - 1\end{aligned}$$

Portanto,

$$\hat{\alpha} = \frac{2 \bar{X} - 1}{1 - \bar{X}}$$

é o estimador para  $\alpha$  pelo métodos dos momentos.





# Método dos Momentos: Exercícios

Murteira et al (2015)

# 3

1. Seja uma população com função probabilidade

$$f(x|\theta) = \theta(1-\theta)^x \quad (x = 0, 1, 2, 3, \dots),$$

onde  $0 < \theta < 1$ . Sabe-se que  $E(X) = (1-\theta)/\theta$ . Recolhida uma amostra casual de dimensão 1000 observou-se  $\sum_{i=1}^{1000} x_i = 980$ .

- a) Obtenha uma estimativa para  $\theta$  pelo método dos momentos.
- b) Determine o estimador de máxima verosimilhança para  $\theta$ .
- c) Calcule, justificando, a estimativa da máxima verosimilhança para a média da população.
- d) Reparametrize a distribuição em função de  $\mu = E(X)$ , e utilize a nova função probabilidade para estimar a média da população.
- e) Mostre que  $T = \sum_{i=1}^{1000} X_i$  é estatística suficiente para  $\theta$ .



## Exercício 1 a)

$$f(x|\theta) = \theta(1-\theta)^x \quad (x=0, 1, 2, 3, \dots) \quad , \quad \text{onde } 0 < \theta < 1$$

Sabe-se que :  $E(x) = \frac{1-\theta}{\theta}$

Amostra :  $n = 1000$  ,  $\sum_{i=1}^{1000} x_i = 980$

## Exercício 1 a)

$$E(x) = \frac{\sum_{i=1}^n x_i}{n} \Leftrightarrow \frac{1-\theta}{\theta} = \bar{x} \Leftrightarrow 1-\theta = \bar{x}\theta \Leftrightarrow \bar{x}\theta + \theta = 1 \Leftrightarrow \theta(\bar{x}+1) = 1 \Leftrightarrow$$

$$\Leftrightarrow \boxed{\hat{\theta} = \frac{1}{\bar{x}+1}} \rightarrow \text{Estimador MM}$$

Estimativa MM:  $\hat{\theta} = \frac{1}{\bar{x}+1}$

Na amostra observou-se  $\sum_{i=1}^{1000} x_i = 980 \Rightarrow \bar{x} = \frac{\sum_{i=1}^{1000} x_i}{1000} = \frac{980}{1000} = 0.98$

Logo, a estimativa MM é:  $\hat{\theta} = \frac{1}{0.98+1} = \frac{50}{99} \approx 0.5051$

3. Considere uma variável aleatória  $X$  cuja distribuição depende dos parâmetros  $\alpha$  e  $\theta$ , para a qual se tem  $E(X) = \alpha\theta$  e  $\text{Var}(X) = \alpha\theta^2$ . Sabendo que numa amostra casual de 320 observações se obteve  $\sum_{i=1}^{320} x_i = 22.2$  e  $\sum_{i=1}^{320} x_i^2 = 535.8$ , apresente, justificando, uma estimativa para os parâmetros desconhecidos.



## Exercício 3

$$X \rightarrow E(X) = \alpha \theta \quad \text{e} \quad \text{Var}(X) = \alpha \theta^2$$

$$\text{Amostra: } n = 320, \quad \sum_{i=1}^{320} x_i = 22.2, \quad \sum_{i=1}^{320} x_i^2 = 535.8$$

Método dos Momentos

$$E(X) = \frac{\sum_{i=1}^n x_i}{n} \quad \text{e} \quad E(X^2) = \frac{\sum_{i=1}^n x_i^2}{n}$$

$$E(X^2) = ? \rightarrow \text{Var}(X) = E(X^2) - [E(X)]^2 \Leftrightarrow E(X^2) = \text{Var}(X) + [E(X)]^2 \Leftrightarrow E(X^2) = \alpha \theta^2 + (\alpha \theta)^2 \Leftrightarrow$$

$$\Leftrightarrow E(X^2) = \alpha \theta^2 + \alpha^2 \theta^2$$

# Exercício 3

$$\begin{cases} E(X) = \bar{X} \\ E(X^2) = \frac{\sum_{i=1}^n X_i^2}{n} \end{cases} \quad (I) \quad \begin{cases} \alpha \theta = \bar{X} \\ \alpha \theta^2 + \alpha^2 \theta^2 = \frac{\sum_{i=1}^n X_i^2}{n} \end{cases} \quad (II) \quad \begin{cases} \alpha = \frac{X}{\theta} \\ \left(\frac{\bar{X}}{\theta}\right) \theta^2 + \left(\frac{\bar{X}}{\theta}\right)^2 \theta^2 = \frac{\sum_{i=1}^n X_i^2}{n} \end{cases} \quad (III)$$

$$\begin{cases} \bar{X} \theta + \bar{X}^2 = \frac{\sum_{i=1}^n X_i^2}{n} \end{cases} \quad (IV) \quad \begin{cases} \bar{X} \theta = \frac{\sum_{i=1}^n X_i^2}{n} - \bar{X}^2 \end{cases} \quad (V) \quad \begin{cases} \theta = \frac{\sum_{i=1}^n X_i^2}{n \bar{X}} - \bar{X} \end{cases} \quad (VI)$$

$$\begin{cases} \alpha^2 = \frac{\bar{X}}{\theta^2} \\ \theta^2 = \frac{\sum_{i=1}^n X_i^2 - n \bar{X}^2}{n \bar{X}} \end{cases} \quad (VII) \quad \begin{cases} \alpha^2 = \bar{X} \cdot \frac{n \bar{X}}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \end{cases} \quad (VIII) \quad \begin{cases} \alpha^2 = \frac{n \bar{X}^2}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \\ \theta^2 = \frac{\sum_{i=1}^n X_i^2 - n \bar{X}^2}{n \bar{X}} \end{cases} \quad (IX)$$

↓  
Estimadores MM

Estimativas MM:  $\alpha^2 = \frac{n \bar{X}^2}{\sum_{i=1}^n X_i^2 - n \bar{X}^2}$  e  $\theta^2 = \frac{\sum_{i=1}^n X_i^2 - n \bar{X}^2}{n \bar{X}}$

## Exercício 3

Da amostra observada, tem-se:

$$n = 320$$

$$\sum_{i=1}^n x_i = 22.2 \quad \Rightarrow \quad \bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{22.2}{320} = 0.069375$$

$$\sum_{i=1}^n x_i^2 = 535.8$$



## Exercício 3

Logo, as estimativas MM são:

$$\hat{\alpha} = \frac{320 \times 0.069375^2}{535.8 - 320 \times 0.069375^2} \approx 0.00288$$

$$\hat{\beta} = \frac{535.8 - 320 \times 0.069375^2}{320 \times 0.069375} \approx 24.06576$$

4. Num saco existem  $\theta$  bolas, numeradas de 1 a  $\theta$ . Extraiu-se, ao acaso e com reposição, uma amostra de três bolas, tendo-se observado: 13, 5, 9.
- Calcule a estimativa do número de bolas existentes no saco, pelo método dos momentos.
  - Obtenha a estimativa da máxima verosimilhança para  $\theta$ .
  - Com base nas estimativas obtidas nas alíneas anteriores o que pode dizer sobre os estimadores que as originaram.



## Exercício 4 a)

Saco com  $\theta$  bolas (numeradas de 1 a  $\theta$ )  
Amostra com reposição ( $n=3$ ): 13, 5, 9

$X$  - v.a. do nº obtido na seta aceita

$X$  ~ Uniforme Discreta  $\Rightarrow f(x) = \frac{1}{\theta}$  ( $x=1, 2, \dots, \theta$ ),  $E(x) = \frac{\theta+1}{2}$

Para estimação MM:

$$E(x) = \frac{\sum_{i=1}^n x_i}{n} \quad (\Rightarrow) \quad \frac{\theta+1}{2} = \bar{x} \quad (\Rightarrow) \quad \boxed{\tilde{\theta} = 2\bar{x} - 1} \rightarrow \text{Estimador MM}$$

$\underbrace{\frac{\theta+1}{2}} \quad \underbrace{\bar{x}}$

## Exercício 4 a)

• Estimativa MM:  $\tilde{\theta} = 2\bar{x} - 1 = 2 \times \frac{13+5+9}{3} - 1 \quad (\Rightarrow) \quad \tilde{\theta} = 17$

$\underbrace{\hspace{10em}}_{\bar{x}}$   
(obtido da amostra observada)

Nota: O método momentos pode fornecer estimativas não admissíveis.

Por exemplo, se a amostra observada fosse  $(1, 3, 14)$ , teríamos como estimativa para o n.º de bolas no saco

$$\tilde{\theta} = 2\bar{x} - 1 = 2 \times \frac{1+3+14}{3} - 1 = 11,$$

que não é possível pois observamos a bola 14!

5. Considere uma amostra casual de dimensão  $n$  retirada de uma população com distribuição dada por:

$$f(x|\theta) = \frac{1}{2\theta}, \quad (-\theta < x < \theta), \quad \text{para } \theta > 0.$$

Calcule um estimador para  $\theta$  pelo método dos momentos.



## Exercício 5

$$f(x|\theta) = \frac{1}{2\theta}, \quad (-\theta < x < \theta), \quad \text{onde } \theta > 0 \quad \rightarrow \text{Amostra casual: } n$$

Estimação MM

$$E(X) = \frac{\sum_{i=1}^n x_i}{n}$$

$$\begin{aligned} \bullet E(X) = ? \quad \rightarrow \quad E(X) &= \int_{-\theta}^{\theta} x f(x|\theta) dx = \int_{-\theta}^{\theta} x \cdot \frac{1}{2\theta} dx = \frac{1}{2\theta} \int_{-\theta}^{\theta} x dx = \frac{1}{2\theta} \left[ \frac{x^2}{2} \right]_{-\theta}^{\theta} = \\ &= \frac{1}{2\theta} \left[ \frac{\theta^2}{2} - \frac{(-\theta)^2}{2} \right] = \frac{1}{2\theta} \left( \frac{\theta^2}{2} - \frac{\theta^2}{2} \right) = \frac{1}{2\theta} \times 0 = 0 \end{aligned}$$

É impossível obter estimador MM pelo 1º momento populacional. Vamos então recorrer aos segundos momentos.

## Exercício 5


$$E(x^2) = \frac{\sum_{i=1}^n x_i^2}{n}$$

$$\begin{aligned} E(x^2) &= \int_{D_x} x^2 f(x|\theta) dx = \int_{-\theta}^{\theta} x^2 \frac{1}{2\theta} dx = \frac{1}{2\theta} \int_{-\theta}^{\theta} x^2 dx = \frac{1}{2\theta} \left[ \frac{x^3}{3} \right]_{-\theta}^{\theta} = \\ &= \frac{1}{2\theta} \left[ \frac{\theta^3}{3} - \frac{(-\theta)^3}{3} \right] = \frac{1}{2\theta} \left( \frac{\theta^3}{3} + \frac{\theta^3}{3} \right) = \frac{1}{2\theta} \times \frac{2\theta^3}{3} = \frac{\theta^2}{3} \end{aligned}$$

Logo,

$$E(x^2) = \frac{\sum_{i=1}^n x_i^2}{n} \quad (=) \quad \frac{\theta^2}{3} = \frac{\sum_{i=1}^n x_i^2}{n} \quad (=) \quad \theta^2 = \frac{3 \sum_{i=1}^n x_i^2}{n} \Rightarrow \theta^2 = \sqrt{\frac{3 \sum_{i=1}^n x_i^2}{n}} \rightarrow \text{Estimador M}$$

Porque é que a outra solução não é possível?



# Método da Máxima Verosimilhança

Estimadores

# 4



# 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

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

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

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

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

Passo 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:

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

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

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

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

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

# 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

# 5

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://ProbabilidadesEstatistica_2019(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:

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

## 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:

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



# Método da Máxima Verosimilhança: Exercícios

Murteira et al (2015)

# 6

1. Seja uma população com função probabilidade

$$f(x|\theta) = \theta(1-\theta)^x \quad (x = 0, 1, 2, 3, \dots),$$

onde  $0 < \theta < 1$ . Sabe-se que  $E(X) = (1-\theta)/\theta$ . Recolhida uma amostra casual de dimensão 1000 observou-se  $\sum_{i=1}^{1000} x_i = 980$ .

- Obtenha uma estimativa para  $\theta$  pelo método dos momentos.
- Determine o estimador de máxima verosimilhança para  $\theta$ .
- Calcule, justificando, a estimativa da máxima verosimilhança para a média da população.
- Reparametrize a distribuição em função de  $\mu = E(X)$ , e utilize a nova função probabilidade para estimar a média da população.
- Mostre que  $T = \sum_{i=1}^{1000} X_i$  é estatística suficiente para  $\theta$ .



# Exercício 1

$$f(x|\theta) = \theta(1-\theta)^x \quad (x=0, 1, 2, 3, \dots) \quad , \quad \text{onde } 0 < \theta < 1$$

Sabe-se que :  $E(x) = \frac{1-\theta}{\theta}$

Amostra :  $n = 1000$  ,  $\sum_{i=1}^{1000} x_i = 980$



## Exercício 1 b)

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta) = \prod_{i=1}^n \theta(1-\theta)^{x_i} = \theta^n (1-\theta)^{\sum_{i=1}^n x_i} = \theta^n (1-\theta)^{n\bar{x}} \quad (0 < \theta < 1)$$

$$l(\theta) = \ln[L(\theta)] = \ln[\theta^n (1-\theta)^{n\bar{x}}] = \ln(\theta^n) + \ln[(1-\theta)^{n\bar{x}}] = n \ln(\theta) + n\bar{x} \ln(1-\theta) \quad (0 < \theta < 1)$$

$$\frac{d l(\theta)}{d \theta} = 0 \quad (\Leftrightarrow) \quad \frac{n}{\theta} - \frac{n\bar{x}}{1-\theta} = 0 \quad (\Leftrightarrow) \quad n(1-\theta) = n\bar{x}\theta \quad (\Leftrightarrow) \quad n - n\theta = n\bar{x}\theta \quad (\Leftrightarrow)$$

$$(\Leftrightarrow) \quad n\bar{x}\theta + n\theta = n \quad (\Leftrightarrow) \quad \theta(n\bar{x} + n) = n \quad (\Leftrightarrow) \quad \theta = \frac{n}{n\bar{x} + n} \quad (\Leftrightarrow) \quad \theta = \frac{n}{n(\bar{x} + 1)} \quad (\Leftrightarrow)$$

$$(\Leftrightarrow) \quad \hat{\theta} = \frac{1}{\bar{x} + 1}$$

## Exercício 1 b)

$$\frac{d^2 l(\theta)}{d\theta^2} = -\frac{n}{\theta^2} - \frac{n\bar{x}}{(1-\theta)^2} = -\underbrace{\left(\frac{n}{\theta^2} + \frac{n\bar{x}}{(1-\theta)^2}\right)}_{>0} < 0 \quad \checkmark$$

Logo, o estimador MV é:  $\hat{\theta} = \frac{1}{\bar{x} + 1}$ .

## Exercício 1 c)

$E(x) = \frac{1-\theta}{\theta}$  é uma função de  $\theta$

Logo, pela propriedade da invariância dos estimadores MV, obtém-se:

$$\hat{E}(x) = \left( \frac{1-\hat{\theta}}{\hat{\theta}} \right) = \frac{1-\hat{\theta}}{\hat{\theta}} = \frac{1-50/99}{50/99} = 0.98$$

7. O tempo que um aluno leva a responder a uma pergunta do exame é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda$ . Numa amostra casual de 40 observações verificou-se um total de 480 minutos.
- Obtenha o estimador da máxima verosimilhança para  $\lambda$ .
  - Determine a estimativa da máxima verosimilhança para a percentagem de perguntas que são resolvidas em menos de 15 minutos.
  - Se um exame tiver oito questões, obtenha uma estimativa para a probabilidade de as resolver todas, sabendo que a duração da prova é 2 horas.



## Exercício 7 a)

$X$  - v.a. tempo resposta a uma questão, em minutos  
 $X \sim \text{Ex}(\lambda) \Rightarrow f(x|\lambda) = \lambda e^{-\lambda x} \quad (x > 0)$ , onde  $\lambda > 0$   
Amostra:  $n = 40$ ,  $\sum_{i=1}^{40} x_i = 480$

## Exercício 7 a)

$$L(\lambda) = \prod_{i=1}^n f(x_i; \lambda) = \prod_{i=1}^n \lambda e^{-\lambda x_i} = \lambda^n e^{-\lambda \sum_{i=1}^n x_i} = \lambda^n e^{-\lambda \sum_{i=1}^n x_i} = \lambda^n e^{-\lambda n \bar{x}} \quad (\lambda > 0)$$

$$l(\lambda) = \ln [L(\lambda)] = \ln (\lambda^n e^{-\lambda n \bar{x}}) = \ln (\lambda^n) + \ln (e^{-\lambda n \bar{x}}) = n \ln (\lambda) - \lambda n \bar{x} \quad (\lambda > 0)$$

$$\frac{d l(\lambda)}{d \lambda} = 0 \Leftrightarrow \frac{n}{\lambda} - n \bar{x} = 0 \Leftrightarrow \frac{n}{\lambda} = n \bar{x} \Leftrightarrow \lambda n \bar{x} = n \Leftrightarrow \lambda = \frac{n}{n \bar{x}} \Leftrightarrow \hat{\lambda} = \frac{1}{\bar{x}}$$

$$\frac{d^2 l(\lambda)}{d \lambda^2} = -\frac{n}{\lambda^2} < 0 \quad \checkmark$$

Logo, o estimador MV é:  $\hat{\lambda} = \frac{1}{\bar{x}}$

## Exercício 7 b)

Quer-se estimativa MV para :

$$P(X < 15) = \int_0^{15} \lambda e^{-\lambda x} dx = \left[ -e^{-\lambda x} \right]_0^{15} = -e^{-15\lambda} - (-e^0) = 1 - e^{-15\lambda}$$

Recorrendo à propriedade da invariância dos estimadores MV, tem-se que :

$$\hat{P}(X < 15) = 1 - e^{-15\hat{\lambda}}$$

Sabendo que  $\hat{\lambda} = \frac{1}{\bar{x}}$  e que da amostra tem-se:  $\bar{x} = \frac{\sum_{i=1}^{40} x_i}{40} = \frac{480}{40} = 12$ , obtém-se:  $\hat{\lambda} = \frac{1}{12}$

Logo ;

$$\hat{P}(X < 15) = 1 - e^{-\frac{15}{12}} \approx 0.7135 \quad (71.35\%)$$

## Exercício 7 c)

Tempo a responder a oito questões:  $\sum_{i=1}^8 X_i$ . Logo, quer-se:


$$P\left(\sum_{i=1}^8 X_i \leq 120\right)$$

$$\text{Como } X_i \sim \text{Ex}(\lambda) \Rightarrow \sum_{i=1}^8 X_i \sim G(8, \lambda) \Rightarrow \underbrace{2\lambda \sum_{i=1}^8 X_i}_Y \sim \chi^2(2 \times 8) \Rightarrow Y \sim \chi^2(16)$$

Logo, recorrendo à propriedade de invariância dos estimadores MV, obtém-se:

$$\hat{P}\left(\sum_{i=1}^8 X_i \leq 120\right) = P\left(2\lambda \sum_{i=1}^8 X_i \leq 2 \times \frac{1}{12} \times 120\right) = P\left(Y \leq 20\right) \approx 0.78$$

$\downarrow$   
 $\chi^2(16)$





8. Admite-se que o tempo de reparação de certo tipo de máquinas,  $X$ , segue uma distribuição normal de parâmetros desconhecidos. A fim de estimar esses parâmetros recolheu-se uma amostra aleatória de tempos de reparação (em minutos). Os dados são os seguintes:

$$n = 10, \sum_{i=1}^{10} x_i = 846 \text{ e } \sum_{i=1}^{10} x_i^2 = 71607.$$

Estime a probabilidade do tempo de reparação de uma máquina ser inferior a 83 minutos.



## Exercício 8

$X$  - v.a. tempo reparação, em minutos

$X \sim N(\mu, \sigma^2)$  → Amostra:  $n = 10$ ,  $\sum_{i=1}^{10} x_i = 846$ ,  $\sum_{i=1}^{10} x_i^2 = 71607$

Quer-se  $\hat{P}(X < 83)$ .

Porque  $P(X < 83)$  é uma função de  $\mu$  e  $\sigma^2$ , temos de recorrer à propriedade da invariância dos estimadores MV.

## Exercício 8

1º) Estimativa MV de  $\mu$  e  $\sigma^2$

O método MV gera as estimativas:  $\hat{\mu} = \bar{x}$  e  $\hat{\sigma}^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$

Então, pelos dados da amostra obtém-se:

$$\hat{\mu} = \bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{846}{10} = 84.6$$

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \\ &= \frac{1}{n} \left[ \sum_{i=1}^n x_i^2 - \sum_{i=1}^n 2x_i\bar{x} + \sum_{i=1}^n \bar{x}^2 \right] = \frac{1}{n} \left[ \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + n\bar{x}^2 \right] = \\ &= \frac{1}{n} \left( \sum_{i=1}^n x_i^2 - 2\bar{x} \cdot n\bar{x} + n\bar{x}^2 \right) = \frac{1}{n} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = \\ &= \frac{\sum_{i=1}^n x_i^2}{n} - \bar{x}^2 = \frac{71607}{10} - 84.6^2 = 3.54\end{aligned}$$

## Exercício 8

2º) Aplicação da propriedade da invariância dos estimadores MV

$$\hat{P}(X < 83) \approx 0.1976 \rightarrow \text{normalcdf}(-10^{99}, 83, 84.6, \sqrt{3.54})$$

↓

$$N(84.6, 3.54)$$

Isto é, recorrendo à Tabela 4,

$$\begin{aligned}\hat{P}(X < 83) &= P\left(\frac{X - \hat{\mu}}{\hat{\sigma}} < \frac{83 - 84.6}{\sqrt{3.54}}\right) = P(Z < -0.85) = \Phi(-0.85) = 1 - \Phi(0.85) \\ &= 1 - 0.8023 = 0.1977\end{aligned}$$

# Obrigada!

Questões?

