



Lisbon School  
of Economics  
& Management  
Universidade de Lisboa

A decorative graphic at the top of the slide features a blue line graph with circular markers and a green area chart, set against a background of vertical dashed lines. The area chart has a light green top layer and a light blue bottom layer.

# Estatística II

Licenciatura em Gestão do Desporto  
2.º Ano/2.º Semestre  
2024/2025

# Aulas Teórico-Práticas N.º 7 e 8 (Semana 4)

**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 3)

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

## Aulas Teórico-Práticas (Semanas 4 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: Exercícios

(continuação)

1

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 a)

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

$$E(X) = \frac{1-\theta}{\theta} = \mu'_1$$

$$\text{Amostra casual: } (X_1, \dots, X_{1000}) \rightarrow \sum_{i=1}^{1000} x_i = 980$$

$$\bar{x} = \frac{980}{1000} = 0.98$$

a)  $\theta = ?$

$$1^{\circ} \text{ momento ordinário da população: } \mu'_1 = E(X) = \frac{1-\theta}{\theta}$$

$$1^{\circ} \text{ momento ordinário da amostra: } \frac{1}{n} \sum_{i=1}^m X_i = \bar{x}$$

Método dos momentos:

$$\mu'_1 = \frac{\sum_{i=1}^{1000} X_i}{1000} \quad (\Leftrightarrow) \quad \frac{1-\theta}{\theta} = \frac{\sum_{i=1}^{1000} X_i}{1000} \quad (\Leftrightarrow)$$

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

## Exercício 1 a)

Estimador:  $\theta = \frac{1}{\bar{X}+1}$

Estimativa:  $\tilde{\theta} = \frac{1}{\bar{x}+1} = \frac{1}{0.98+1} \approx 0.5051$

Nota:

Momento ordinário de ordem  $k$  (ou momento de ordem  $k$  em relação à origem):

- $\mu'_k = E(X^k)$

- Momentos ordinários amostrais de ordem  $k$ :

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

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

V. A. com  $F_x(x|\alpha, \theta)$

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

Amostra casual:  $(X_1, \dots, X_{320})$

$$\begin{aligned} \rightarrow \sum_{i=1}^{320} x_i &= 22.2 \\ \rightarrow \sum_{i=1}^{320} x_i^2 &= 535.8 \end{aligned}$$

Vamos usar o método dos momentos. Não é possível usar o método da máxima verosimilhança porque não conhecemos a forma funcional de  $f(x|\alpha, \theta)$  e por isso não é possível obter  $L(\alpha, \theta)$ .

## Exercício 3

$$\mu_1' = E(X) = \alpha \theta$$

$$\text{Var}(X) = E(X^2) - E(X)^2 \quad (\Rightarrow) \quad E(X^2) = \text{Var}(X) + E(X)^2$$

$$(\Rightarrow) \quad \mu_2' = \text{Var}(X) + E(X)^2$$

$$\left. \begin{aligned} \mu_1' &= \frac{\sum_{i=1}^{320} x_i}{320} \\ \mu_2' &= \frac{\sum_{i=1}^{320} x_i^2}{320} \end{aligned} \right\} (\Rightarrow) \left\{ \begin{aligned} \alpha \theta &= \bar{x} \\ \alpha \theta^2 + (\alpha \theta)^2 &= \sum_{i=1}^{320} x_i^2 / 320 \end{aligned} \right. (\Rightarrow)$$

$$(\Rightarrow) \left\{ \begin{aligned} \alpha &= \frac{\bar{x}}{\theta} \\ \frac{\bar{x}}{\theta} \theta^2 + \left(\frac{\bar{x}}{\theta}\right)^2 \theta^2 &= \sum_{i=1}^{320} x_i^2 / 320 \end{aligned} \right. (\Rightarrow)$$

## Exercício 3

$$\text{(=)} \left\{ \overline{x} \theta + \overline{x}^2 = \frac{\sum_{i=1}^{320} x_i^2}{320} \text{(=)} \right.$$

$$\text{(=)} \left\{ \overline{x} \theta = \frac{\sum_{i=1}^{320} x_i^2}{320} - \overline{x}^2 \text{(=)} \right\} \left\{ \theta = \frac{\frac{\sum_{i=1}^{320} x_i^2}{320} - \overline{x}^2}{\overline{x}} \text{(=)} \right.$$

$$\text{(=)} \left\{ \begin{aligned} \alpha &= \frac{\overline{x}^2}{\Delta^2} \\ \theta &= \frac{\Delta^2}{\overline{x}} \end{aligned} \right.$$

## Exercício 3

Conclusão :

$$\tilde{\alpha} = \left( \frac{22.2}{320} \right)^2 / \left[ \frac{535.8}{320} - \left( \frac{22.2}{320} \right)^2 \right] = 0.00288$$

$$\tilde{\theta} = \left[ \frac{535.8}{320} - \left( \frac{22.2}{320} \right)^2 \right] / \left( \frac{22.2}{320} \right) = 24.06576$$


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)

$\theta$  bolas

Amostra casual:  $(X_1, X_2, X_3)$



(Amostra com reposição)

$$\left. \begin{array}{l} x_1 = 13 \\ x_2 = 5 \\ x_3 = 9 \end{array} \right\}$$

$$f_X(x|\theta) = \frac{1}{\theta} \quad (x = 1, 2, \dots, \theta)$$

$X \sim U(1, \theta)$  Distribuição uniforme discreta

$$E(X) = \frac{\theta+1}{2} = \mu_1'$$

$$a) \mu_1' = \frac{\sum_{i=1}^3 X_i}{3} \quad (\Rightarrow) \quad \frac{\theta+1}{2} = \bar{X} \quad (\Rightarrow) \quad \theta = \underbrace{2\bar{X}-1}_{\text{Estimador}}$$

$$\text{estimativa: } \tilde{\theta} = 2\bar{x} - 1 = 2\left(\frac{13+5+9}{3}\right) - 1 = 17 \text{ bolas}$$

## Exercício 4 a)

Com a amostra observada o método dos momentos resulta numa estimativa admissível para  $\theta$  uma vez que não se observou nenhuma bola com numero superior a 17. No entanto, não é garantido que isto se verifique em todas as amostras. Por exemplo:

$$(x_1, x_2, x_3) = (1, 2, 9) \Rightarrow \hat{\theta} = 2 \frac{(1 + 2 + 9)}{3} - 1 = 7.$$

Com esta amostra o método dos momentos já não resultava numa estimativa admissível para  $\theta$  uma vez que já se observou a bola nº 9, logo não podem existir apenas 7 bolas.

O método dos momentos é bom para estimar parâmetros referentes a momentos de variáveis aleatórias. Neste exercício, o parâmetro que estamos a estimar é o limite do suporte da variável aleatória (distribuição da população). A qualidade de um estimador não se deve avaliar olhando apenas para estimativas particulares (estejam estas muito próximas ou muito afastadas do verdadeiro valor do parâmetro). Interessa sim estudar o comportamento do estimador em sucessivas amostras, ou seja, estudar a sua distribuição por amostragem. Neste caso seria melhor usar outro estimador (o EMV).

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

$(X_1, \dots, X_n)$  amostra casual

$$f_x(x|\theta) = \frac{1}{2\theta} \quad (-\theta < x < \theta), \quad \theta > 0$$

Distribuição uniforme contínua

$$E(X) = \int_{-\theta}^{\theta} x \cdot f_x(x|\theta) dx =$$

$$= \int_{-\theta}^{\theta} x \cdot \frac{1}{2\theta} dx = \frac{1}{2\theta} \left[ \frac{x^2}{2} \right]_{-\theta}^{\theta} =$$

$$= \frac{1}{2\theta} \left( \frac{\theta^2}{2} - \left( \frac{(-\theta)^2}{2} \right) \right) = \frac{1}{2\theta} \left( \frac{\theta^2}{2} - \frac{\theta^2}{2} \right) = 0$$

Como  $E(X)$  não depende de  $\theta$  vamos tentar o 2º momento:

## Exercício 5

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

## Exercício 5

$$\underline{M.M} : E(X^2) = \sum_{i=1}^m x_i^2 / m \quad (=)$$

$$(\Rightarrow) \frac{\theta^2}{3} = \sum_{i=1}^m x_i^2 / m \quad (=)$$

$$(\Rightarrow) \theta^2 = \frac{3}{m} \sum_{i=1}^m x_i^2 \quad (\Rightarrow) \theta = \pm \sqrt{\frac{3}{m} \sum_{i=1}^m x_i^2}$$


$$\Rightarrow \tilde{\theta} = + \sqrt{\frac{3}{m} \sum_{i=1}^m x_i^2} \quad (\text{porque } \theta > 0)$$

## Exercício 5

Nota: Caso se reparasse que  $X \sim U(-\theta, \theta)$ , então:

$$E(X) = \frac{-\theta + \theta}{2} = 0$$

$$E(X^2) = \text{Var}(X) + \underbrace{E(X)}_0^2 = \frac{(\theta - (-\theta))^2}{12} = \frac{(2\theta)^2}{12} = \frac{4\theta}{3} = \frac{\theta}{3}$$



# Método da Máxima Verosimilhança

Estimadores

# 2

# 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

# 3

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 \(uevora.pt\)](#)



## 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:

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

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 b)

$\theta \in (0, 1)$

$$L(\theta) = f(x_1, \dots, x_m | \theta) = \prod_{i=1}^m f(x_i | \theta) = \prod_{i=1}^m \theta (1-\theta)^{x_i} = \\ = \theta^m (1-\theta)^{\sum_{i=1}^m x_i} \quad (0 < \theta < 1)$$

$$l(\theta) = \ln \{L(\theta)\} = \\ = \ln \left\{ \theta^m (1-\theta)^{\sum_{i=1}^m x_i} \right\} = \\ = m \ln(\theta) + \sum_{i=1}^m x_i \ln(1-\theta) \quad (0 < \theta < 1)$$

Nota:

$$\begin{array}{ccc} x_1 & x_2 & x_1 + x_2 \\ a \cdot a & = & a \\ \prod_{i=1}^m a^{x_i} & = & a^{\sum_{i=1}^m x_i} \end{array}$$

$$\frac{d}{d\theta} \{l(\theta)\} = 0 \Leftrightarrow \frac{m}{\theta} - \frac{\sum_{i=1}^m x_i}{1-\theta} = 0 \quad (\Leftrightarrow)$$

$$(\Leftrightarrow) \frac{m}{\theta} = \frac{\sum_{i=1}^m x_i}{1-\theta} \quad (\Leftrightarrow) \frac{1-\theta}{\theta} = \frac{\sum_{i=1}^m x_i}{m} = \bar{x} \quad (\Leftrightarrow)$$

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

## Exercício 1 b)

$$\frac{d^2}{d\theta^2} l(\hat{\theta}) = \frac{d}{d\theta} \left\{ \frac{m}{\theta} - \frac{\sum_{i=1}^m x_i}{1-\theta} \right\} \Bigg|_{\theta=\hat{\theta}} = -\frac{m}{\theta^2} - \frac{\sum_{i=1}^m x_i}{(1-\theta)^2} \Bigg|_{\theta=\hat{\theta}}$$
$$= -\frac{m}{\underbrace{\hat{\theta}^2}_{>0}} - \frac{\sum_{i=1}^m x_i}{\underbrace{(1-\hat{\theta})^2}_{>0}} < 0 \quad \text{para } \underbrace{(0 < \hat{\theta} < 1)}_{\substack{\leftrightarrow \text{Valores admissíveis} \\ \text{de } \theta}}$$

porque  $m=1000$  e  $\sum_{i=1}^{1000} x_i = 980$

Conclusão  $\hat{\theta} = \frac{1}{1+\bar{X}}$  é  $\theta$  estimador da máxima verossimilhança para  $\theta$ .


Nota:  $\hat{\theta} = \frac{1}{1+\bar{X}}$  é um estimador (variável aleatória)

$\hat{\theta} = \frac{1}{1+\bar{x}}$  é uma estimativa ( $\hat{\theta} \in \mathbb{R}$ )

## Exercício 1 c)

c)  $\mu_x = \frac{1-\theta}{\theta} = \frac{1}{\theta} - 1 = \tau(\theta)$  função de  $\theta$

Queremos  $\hat{\mu}_x = \tau(\hat{\theta})$  e temos  $\hat{\theta}$



$\tau(\theta)$  é monotona decrescente  
em  $0 < \theta < 1$

$\tau(\theta)$  é função biunívoca de  $\theta$   
em  $0 < \theta < 1$

↓  
Pode-se usar a propriedade de  
invariância de EMV

$$\hat{\theta} = 0.5051$$

$$\hat{\mu}_x = \tau(\hat{\theta}) = \tau(\hat{\theta}) = \frac{1}{\hat{\theta}} - 1 = \frac{1}{0.5051} - 1 = 0.9798$$

Para obter igual às soluções usar  $\hat{\theta} = \frac{1}{0.98+1}$  sem arredondar

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 b)

$$b) L(\theta) = \prod_{x_i} f(x_1, x_2, x_3 | \theta) = \prod_{i=1}^3 f(x_i | \theta) = \frac{1}{\theta^3} \quad (\theta = x_{(3)}, x_{(3)} + 1, x_{(3)} + 2, \dots)$$

$\Theta = \{x_{(3)}, x_{(3)} + 1, x_{(3)} + 2, \dots\}$   $\rightarrow$  espaço - parâmetro discreto  
 $\rightarrow$  não existe derivada em ordem a  $\theta$

Como maximizar  $L(\theta)$  em ordem a  $\theta$  ?

$$L(\theta) = \frac{1}{\theta^3} \quad (\theta = x_{(3)}, x_{(3)} + 1, x_{(3)} + 2, \dots)$$

- $L(\theta)$  é função decrescente de  $\theta$
- Vamos escolher o menor valor  $\theta \in \Theta$
- $L(\theta)$  é maximizada em  $\theta = x_{(3)}$
- $\hat{\theta} = \underset{\theta}{\operatorname{argmax}} \{L(\theta)\} = \underline{x_{(3)}}$  (Máximo da amostra)  
 $\hookrightarrow$  Estimador da M.V.



## Exercício 4 b)

Conclusão : A estimativa da máxima verossimilhança para  $\theta$  é  $\hat{\theta} = x_{(3)} = 13$

Comentário: O método da máxima verossimilhança escolhe o maior valor observado como estimativa o numero de bolas no saco. Isto significa que, no contexto desde problema, e independentemente da amostra observada, o método da máxima verossimilhança nunca estima valores não admissíveis para  $\theta$ . Vimos em a) que tais estimativas absurdas podem acontecer com o método dos momentos.

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)

$X \equiv$  Tempo que o aluno demora a responder a uma pergunta do exame (em minutos)

$$X \sim \text{ex}(\lambda), \lambda > 0 \quad f_x(x|\lambda) = \lambda e^{-\lambda x} \quad (x > 0)$$

Amostra casual ( $n=40$ ):  $(x_1, \dots, x_{40})$

$$\sum_{i=1}^{40} x_i = 480 \quad \bar{x} = \frac{480}{40} = 12$$

a)

$$\begin{aligned} L(\lambda) &= f_x(x_1, \dots, x_{40} | \lambda) = \prod_{i=1}^{40} f_x(x_i | \lambda) = \\ &= \prod_{i=1}^{40} \lambda e^{-\lambda x_i} = \lambda^{40} e^{-\lambda \sum_{i=1}^{40} x_i} \end{aligned}$$

$$l(\lambda) = \ln[L(\lambda)] = \ln\left(\lambda^{40} e^{-\lambda \sum_{i=1}^{40} x_i}\right) =$$

## Exercício 7 a)

$$= 40 \ln(\lambda) - \lambda \sum_{i=1}^{40} x_i$$

$$\frac{d}{d\lambda} \ell(\lambda) = \frac{40}{\lambda} - \sum_{i=1}^{40} x_i = 0 \quad (\Rightarrow)$$

$$(\Rightarrow) \frac{40}{\lambda} = \sum_{i=1}^{40} x_i \quad (\Rightarrow) \hat{\lambda} = \frac{40}{\sum_{i=1}^{40} x_i} = \frac{1}{\bar{x}}$$

Condição de 2ª ordem:

$$\frac{d^2}{d\lambda^2} \ell(\hat{\lambda}) = \frac{d}{d\lambda} \left( \frac{40}{\lambda} - \sum_{i=1}^{40} x_i \right) = -\frac{40}{\lambda^2} < 0$$

$\left| \lambda = \frac{1}{\bar{x}} \right| \lambda = \frac{1}{\bar{x}}$

Conclusão:  $\hat{\lambda} = \frac{1}{\bar{X}}$  é o estimador da máxima verossimilhança para  $\lambda$ .

## Exercício 7 b)

**b)** Percentagem = Probabilidade  $\times$  100

$$P(X < 15) = \int_0^{15} f_x(x|\lambda) dx = \int_0^{15} \lambda e^{-\lambda x} dx =$$

$$= [-e^{-\lambda x}]_0^{15} = -e^{-15\lambda} - (-e^{-0}) = 1 - e^{-15\lambda} =$$

$F(\lambda) \rightarrow$  função estritamente crescente de  $\lambda$

$F(\lambda)$  é função biunívoca de  $\lambda$ , logo podemos

usar a propriedade de invariância do EMV:

$$F(\hat{\lambda}) = F(\hat{\lambda}) = 1 - e^{-15\hat{\lambda}} = 1 - e^{-\frac{15}{12}} = 0.7135$$

$$\hat{\lambda} = \frac{1}{\bar{x}} = \frac{1}{12} \quad \text{exame} = 2 \text{ h} = 120 \text{ min}$$

# Exercício 7 c)

$$X \equiv \text{Tempo 1 pergunta (min.)} \sim \text{ex}(\lambda)$$

$$S = \sum_{i=1}^8 X_i \equiv \text{Tempo 8 perguntas (min.)} \sim G(8, \lambda)$$

$$X \sim G(n; \lambda) \Leftrightarrow 2\lambda X \sim \chi^2(2n) \quad Q = 2\lambda S \sim \chi^2(16)$$

$$\begin{aligned} P(S \leq 120) &= P(2\lambda S \leq 2 \times \lambda \times 120) = \\ &= P(Q \leq 240\lambda) \\ &= t(\lambda) \rightarrow \text{função estritamente} \\ &\quad \text{crescente de } \lambda \text{ em } \lambda > 0 \end{aligned}$$

Assim sendo podemos usar a propriedade de invariância do EMV:

$$\begin{aligned} P(S \leq 120) &= P(Q \leq 240\lambda) = P(Q \leq 240\hat{\lambda}) = \\ &= P(Q \leq \frac{240}{12}) = P(Q \leq 20) \rightarrow \text{mão está na} \\ &\quad \text{tabela} \\ &= 0.78 \leftarrow > \text{pchisq}(20, 16) > \text{round}(2) \\ &\quad \quad \quad [1] 0.78 \end{aligned}$$

A1	A	B	C	D	E	F	G
1	0,78						
2							

Usando só as tabelas, o melhor que se podia fazer era usar o valor mais próximo de 20 na tabela da  $\chi^2(16)$ :

$$\begin{aligned} P(Q \leq 20) &= 1 - P(Q > 20) \approx 1 - P(Q > 19.369) = 1 - 0.25 = \\ &= 0.75 \end{aligned}$$

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

$X \equiv$  Tempo de reparação (em minutos)  $\sim N(\mu, \sigma^2)$

$$\frac{X - \mu}{\sigma} \sim N(0, 1)$$

Amostra casual:  $(x_1, \dots, x_{10})$   $m = 10$

$$\sum_{i=1}^{10} x_i = 846$$

$$\sum_{i=1}^{10} x_i^2 = 71607$$

$$f_x(x | \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2}(x - \mu)^2\right\}$$

$$L(\mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{m/2}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^m (x_i - \mu)^2\right\}$$

**Nota:** Já determinados os EMV no exemplo anterior, denotado por exercício 2.



## Exercício 8

$$\begin{aligned}l(\mu, \sigma) &= \ln L(\mu, \sigma^2) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 = \\&= -\frac{n}{2} [\ln(2\pi) + \ln(\sigma^2)] - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 = \\&= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2, \quad (\mu, \sigma^2) \in \Theta,\end{aligned}$$

$$\Theta = \{(\mu, \sigma^2) : \mu \in \mathbb{R} \wedge \sigma^2 \in \mathbb{R}^+\}.$$

## Exercício 8

$$\begin{cases} \frac{\partial}{\partial \mu} \ell(\mu, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{i=1}^m 2(x_i - \mu)(-1) = \frac{\sum_{i=1}^m (x_i - \mu)}{\sigma^2} = 0 \\ \frac{\partial}{\partial \sigma^2} \ell(\mu, \sigma^2) = -\frac{m}{2\sigma^2} + \frac{\sum_{i=1}^m (x_i - \mu)^2}{2\sigma^4} = 0 \end{cases} \quad (=)$$

$$\begin{aligned} (=) \begin{cases} \sum_{i=1}^m (x_i - \mu) = 0 \\ \frac{m}{2\sigma^2} = \frac{\sum_{i=1}^m (x_i - \mu)^2}{2\sigma^4} \end{cases} & \quad (=) \begin{cases} \sum_{i=1}^m x_i = m\mu \\ \sigma^2 = \frac{\sum_{i=1}^m (x_i - \mu)^2}{m} \end{cases} \quad (=) \end{aligned}$$

$$\begin{aligned} (=) \begin{cases} \mu = \frac{\sum_{i=1}^m x_i}{m} = \bar{x} \\ \sigma^2 = \frac{\sum_{i=1}^m (x_i - \bar{x})^2}{m} = s^2 \end{cases} \end{aligned}$$

## Exercício 8

$$P(X < 83) = \Phi\left(\frac{83 - \mu}{\sigma}\right) = \Phi\left(\frac{83 - \mu}{\sqrt{\sigma^2}}\right) = t(\mu, \sigma^2)$$

A função  $t(\mu, \sigma^2)$  é biunívoca (separadamente) em relação a  $\mu$  e a  $\sigma^2$ . Assim sendo, podemos usar a propriedade de invariância do EMV:

$$\widehat{t(\mu, \sigma^2)} = t(\hat{\mu}, \hat{\sigma}^2)$$

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

$$\hat{\sigma}^2 = s^2 = \frac{\sum_{i=1}^{10} x_i^2}{n} - \bar{x}^2 = \frac{71607}{10} - 84.6^2 = 3.54$$

## Exercício 8

então:  $P(\widehat{X} < 83) = \Phi\left(\frac{83 - \hat{\mu}}{\sqrt{\hat{\sigma}^2}}\right) = \Phi\left(\frac{83 - \bar{x}}{\sqrt{s^2}}\right) =$

$$= \Phi\left(\frac{83 - 84.6}{\sqrt{3.54}}\right) \approx \Phi(-0.85)$$
$$= 1 - \Phi(0.85) = 1 - 0.8023$$
$$= 0.1977$$

↑  
Tabela 4

# Obrigada!

## Questões?

