

# Estimação Pontual

## Elementos de Probabilidades e Estatística

1. Inferência Estatística
2. Estimação pontual
3. Método da Máxima Verosimilhança

# 1. Inferência Estatística

Considere-se os estudantes da FCUL entre os quais há uma proporção  $\theta$  que pratica desporto. Escolhem-se ao acaso, com reposição,  $n$  estudantes. Seja  $n = 10$ . Se  $\theta$  fosse conhecido, por exemplo  $\theta = 0.3$ , a probabilidade de encontrar  $x$  praticantes ( $0 \leq x \leq 10$ ) nesse grupo de 10 pessoas é

$$\binom{10}{x} (0.3)^x (0.7)^{10-x} \quad (\text{problema de probabilidade})$$

Na prática, quase sempre  $\theta$  é desconhecido. Neste caso, olharemos para a proporção de praticantes na amostra retirada,  $x/10$ , para tirar conclusões sobre a proporção de praticantes na população donde a amostra foi retirada. (problema de inferência)

## Variável aleatória de interesse

Não passa de uma característica ou atributo crucial para o conhecimento do fenómeno aleatório em estudo.

**Exemplo:** A resistência de certo tipo de mola; idade do estudante de Física; a intenção de voto de certo eleitor.

## População e unidade estatística

- Uma **população** é um conjunto de objetos ou indivíduos que têm em comum pelo menos uma característica de interesse.
- A cada elemento da população damos o nome de **unidade estatística**.

**Exemplo:** Todas as molas produzidas do referido tipo; idade de todos os estudantes de Física; intenção de voto dos eleitores de um país.

## Amostra

Uma **amostra** é um subconjunto de valores da população. Tem que ser selecionada de forma aleatória e deve ser representativa da população de onde foi retirada.

$(x_1, \dots, x_n)$ — amostra observada de dimensão  $n$ .

## Amostragem

O processo de seleção de uma amostra da população de modo a estimar algum aspeto de interesse da mesma é designada **amostragem**.

## Estatística descritiva

A estatística descritiva engloba um conjunto de métodos gráficos e numéricos que possibilitam a apresentação de forma concisa das informações essenciais contidas nos dados.

## Inferência estatística

Conjunto de técnicas que visam a partir de um conjunto representativo de dados, fazer estimativas e previsões com vista a caracterizar um conjunto mais amplo de dados e retirar conclusões.

## Nosso interesse

- Conhecer a população  $X$  corresponde a conhecer a sua função de distribuição  $F_X(x)$ .
- O que é equivalente a conhecer a f.d.p. caso  $X$  seja contínua, ou a f.m.p. caso  $X$  seja discreta.

## Casos a considerar

- Desconhecemos completamente  $F_X(x)$  sabendo-se apenas se  $X$  é discreta ou contínua;
- Admite-se que  $F_X(x)$  pertence a determinada família de distribuições, mas com parâmetros desconhecidos.

## Objetivos da Inferência Estatística

- Estimar  $F_X(x)$  ou estimar os parâmetros de  $F_X(x)$  conhecendo a sua forma;
- Fazer testes em relação aos parâmetros ou em relação à forma de  $F_X(x)$ .

### Estimação de parâmetros:

- pontual;
- intervalar.

### Testes de hipóteses:

- sobre parâmetros;
- sobre a forma de  $F_X(x)$ .

## Amostragem Aleatória

Cada elemento da amostra é obtido totalmente ao acaso da população  $X$  e de forma independente dos outros elementos.

## Amostra Aleatória

A sucessão  $\underline{X} = (X_1, \dots, X_n)$  constitui uma **amostra aleatória (a.a.)** de dimensão  $n$  da população  $X$  se forem **independentes** e **identicamente distribuídas** a  $X$  (**i.i.d.**).

## Amostra

A uma observação particular da a.a.  $\underline{X} = (X_1, \dots, X_n)$  dá-se o nome de **amostra** e representa-se por  $\underline{x} = (x_1, \dots, x_n)$ .

## Caracterização da amostra aleatória

Pelo facto de a a.a. ser constituída por  $n$  v.a. i.i.d. a  $X$ , a caracterização probabilística da a.a.  $\underline{X} = (X_1, \dots, X_n)$  faz-se sem grande dificuldade. Com efeito, temos para os casos:

- discreto - f.p. conjunta de  $\underline{X}$

$$P(\underline{X} = \underline{x}) = P(X_1 = x_1, \dots, X_n = x_n)$$

$$\stackrel{X_i \text{ indep.}}{=} \prod_{i=1}^n P(X_i = x_i)$$

$$\stackrel{X_i \sim X}{=} \prod_{i=1}^n P(X = x_i)$$

- contínuo - f.d.p. conjunta de  $\underline{X}$

$$f_{\underline{X}}(\underline{x}) = f_{X_1, \dots, X_n}(x_1, \dots, x_n)$$

$$\stackrel{X_i \text{ indep.}}{=} \prod_{i=1}^n f_{X_i}(x_i) \stackrel{X_i \sim X}{=} \prod_{i=1}^n f_X(x_i)$$

# Conceitos básicos (cont.)

## Estadística

Uma **estatística** é uma variável aleatória que é função unicamente da amostra aleatória e que não depende de parâmetros desconhecidos. Denota-se usualmente por  $T = T(\underline{X}) = T(X_1, \dots, X_n)$ .

| Exemplos                  | Estatística   | Valor observado da estatística                        |
|---------------------------|---|---|
| média amostral            | $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$              | $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$              |
| var. amostral corrigida   | $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  | $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$  |
| var. amostral não corrig. | $(S')^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ | $(s')^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ |
| mínimo da a.a.            | $X_{(1)} = \min(X_1, \dots, X_n)$                     | $x_{(1)} = \min(x_1, \dots, x_n)$                     |
| máximo da a.a.            | $X_{(n)} = \max(X_1, \dots, X_n)$                     | $x_{(n)} = \max(x_1, \dots, x_n)$                     |

# Conceitos básicos (cont.)

## Parâmetro

O termo parâmetro refere-se a uma quantidade da qual depende a distribuição de uma estatística ou de uma v.a. (e.g.  $\mu$ ,  $\sigma$ , etc.).

## Espaço paramétrico

Corresponde ao conjunto de todos os valores possíveis para o parâmetro desconhecido  $\theta$  e é frequentemente representado por  $\Theta$ .

## Modelo paramétrico

Seja  $X$  uma variável aleatória com função massa/densidade de probabilidade  $f_X(x; \theta)$  pertencente a uma família  $\mathcal{F} = \{f_X(x; \theta), \theta \in \Theta\}$ , onde o valor do parâmetro  $\theta$  é desconhecido.

**Exemplo (Modelo paramétrico):**

$$\{\text{Poisson}(\theta) : \theta \in \mathbb{R}^+\} \quad \text{ou} \quad \{e^{-\theta} \theta^x / x!, x = 0, 1, 2, \dots : \theta \in \mathbb{R}^+\}$$
$$\{\text{exponencial}(\theta) : \theta \in \Theta\} \quad \text{ou} \quad \{\theta e^{-\theta x}, x \geq 0 : \theta \in \Theta\}$$

## Estimador e Estimativa

Uma estatística  $T = T(X_1, \dots, X_n)$  diz-se um **estimador** do parâmetro desconhecido  $\theta$  caso tome valores exclusivamente no espaço paramétrico  $\Theta$ .

O valor concreto do estimador numa amostra particular  $(x_1, \dots, x_n)$ , isto é,  $t = T(x_1, \dots, x_n)$ , chama-se **estimativa** de  $\theta$ .

**Exemplo:** Seja  $X_1, \dots, X_n$  uma amostra aleatória de uma população com distribuição  $N(\mu, \sigma)$ .

Alguns estimadores possíveis para  $\mu$  são

- 1  $\bar{X}$  - média amostral
- 2 mediana amostral
- 3 moda amostral
- 4  $\frac{X_{(1)} + X_{(n)}}{2}$  - centro do intervalo de variação amostral
- 5 ...

**Exemplo:** Admita que vai inquirir  $n$  condutores/as quanto à sua preferência (ou não) por motores elétricos e que as respostas possíveis (admissíveis) neste inquérito são:

- Sim (1), prefiro moto elétrico;
- Não (2), não prefiro motor elétrico.

Procure identificar: a v.a. de interesse, a respetiva distribuição; o parâmetro desconhecido; o modelo e o espaço paramétrico; uma estimativa e um estimador do parâmetro desconhecido.

## V.a. de interesse e sua distribuição

$$\begin{aligned} X &= \text{preferência do/a condutor/a inquirido/a} \\ &= \begin{cases} 1 & \text{(prefere motor elétrico), com prob. } \theta \\ 0 & \text{(não prefere motor elétrico), com prob. } (1 - \theta) \end{cases} \end{aligned}$$

$$X \sim \text{Bernoulli}(\theta)$$

# Conceitos básicos (cont.)

## Parâmetro desconhecido e espaço paramétrico

$$\theta = P(X = 1) = P(\text{prefere motor elétrico}) \quad \Theta = [0, 1]$$

## Modelo paramétrico

$$\{\text{Bernoulli}(\theta) : \theta \in \Theta\} \text{ ou } \{\theta^x(1 - \theta)^{1-x}, x = 0, 1 : \theta \in \Theta\}$$

## A.a. e amostra

$\underline{X} = (X_1, \dots, X_n)$  a.a. de dimensão  $n$  proveniente da população  $X$

$$\underline{x} = (x_1, \dots, x_n) \text{ onde } \underline{x} \in \{0, 1\}^n$$

## Estimativa de $\theta$

Candidata: um valor razoável para  $\theta$  é a proporção observada de condutores/as que preferem motor elétrico, i.e.,  $T(\underline{x}) = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$ .

## Estimador de $\theta$

$$\text{Candidato: } T(\underline{X}) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}.$$

Verificações

- $T(\underline{X})$  só depende de  $\underline{X}$ ;
- $T(\underline{X})$  toma valores em  $\{0, \frac{1}{n}, \frac{2}{n}, \dots, \frac{n-1}{n}, 1\} \subset [0, 1]$

Portanto  $T(\underline{X})$  é um estimador de  $\theta$ .

**Exemplo:** Imagina que estás a estudar o tempo de reação de uma pessoa ao ver uma luz acender-se (por exemplo, num laboratório com um cronómetro). Queres estimar o tempo médio de reação  $\mu$  da população (ou seja, de todas as pessoas).

**Parâmetro desconhecido:**

O tempo médio de reação  $\mu$  da população — não o conheces, é o que queres estimar.

**Estimador (fórmula geral):**

Vais usar a média amostral  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ , onde  $X_1, X_2, \dots, X_n$  são os tempos de reação medidos numa amostra de  $n$  pessoas.

$\bar{X}$  é estimador do tempo médio de reação  $\mu$ . Ela é uma função dos dados amostrais e varia de amostra para amostra.

## Estimativa (valor numérico):

Suponhamos que mediste os tempos de reação de 11 pessoas e obtiveste os seguintes valores (em segundos):

0.22, 0.25, 0.21, 0.24, 0.23, 0.26, 0.22, 0.23, 0.25, 0.20, 0.45

A **média** (estimador aplicado aos dados) é:

$$\bar{X} = \frac{2.76}{11} \approx 0.2509 \text{ segundos.}$$

Esse 0.2509 segundos é a tua estimativa do tempo médio de reação  $\mu$ .

# Como avaliar estimadores?

## Como avaliar estimadores?

- Há um grande número de critérios para avaliar e comparar estimadores de acordo com diferentes propriedades desejáveis.
- Podemos avaliar a **exatidão** de um estimador recorrendo ao seu valor esperado. A exatidão de um estimador reporta-se à proximidade do seu valor esperado do verdadeiro valor do parâmetro desconhecido  $\theta$ .
- Podemos avaliar a **precisão** de um estimador recorrendo à sua variância.
- Podemos avaliar em conjunto as duas características usando o **erro quadrático médio**.

## Estimador centrado; estimador enviesado; enviesamento de um estimador

Um estimador  $T$  de um parâmetro  $\theta$  diz-se **centrado** se e só se

$$E(T) = \theta, \forall \theta \in \Theta.$$

Um estimador  $T$  de um parâmetro  $\theta$  diz-se **não centrado ou enviesado** se

$$\exists \theta \in \Theta : E(T) \neq \theta.$$

O estimador  $T$  de um parâmetro  $\theta$ , possui **enviesamento** dado por

$$\text{bias}_\theta(T) = E(T) - \theta.$$

O **erro quadrático médio** de um estimador  $T$  de um parâmetro  $\theta$  é definido por

$$\begin{aligned} EQM_\theta(T) &= E[(T - \theta)^2] \\ &= V(T) + [E(T) - \theta]^2 \\ &= V(T) + [\text{bias}_\theta(T)]^2. \end{aligned}$$

# Conceitos básicos (cont.)

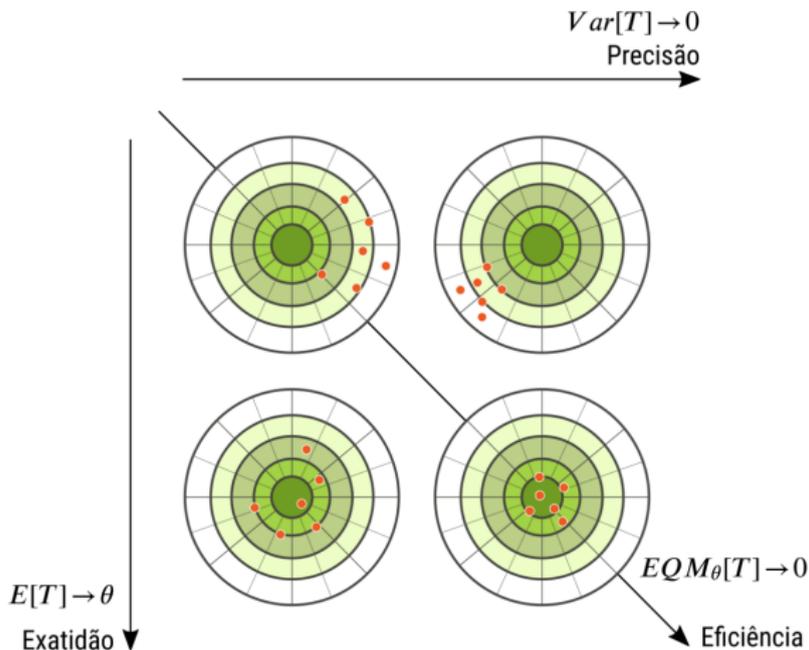


Figura: Imagem retirada de <https://web.tecnico.ulisboa.pt/paulo.soares/pe/>

- Não basta que um estimador de  $\theta$  seja centrado (com exatidão elevada) para garantir estimativas rigorosas. Estas serão tanto mais rigorosas quanto menos o estimador se dispersar em torno do verdadeiro valor do parâmetro desconhecido  $\theta$ .
- $EQM_{\theta}(T)$  quantifica a dispersão esperada do estimador  $T$  em torno do verdadeiro valor do parâmetro desconhecido  $\theta$  e combina duas parcelas:
  - $V(T)$  que diz respeito à variabilidade do estimador e dá ideia da precisão do mesmo;
  - $[\text{bias}_{\theta}]^2$  que se reporta ao quadrado do viés do estimador e reflete a exatidão do mesmo.
- Um estimador será tanto *melhor* quanto menor for o seu EQM.

**Exemplo:** Considere que  $X$  é uma v.a. de interesse com distribuição arbitrária, valor esperado  $\mu$  e variância  $\sigma^2$ .

- (a) Prove que a média da a.a.  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ , e a variância corrigida da a.a.,  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} [\sum_{i=1}^n X_i^2 - n(\bar{X})^2]$ , são estimadores centrados de  $\mu$  e  $\sigma^2$  (respetivamente).
- (b) Demonstre que a variância não corrigida da a.a.,  $(S')^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} [\sum_{i=1}^n X_i^2 - n(\bar{X})^2] = \frac{n-1}{n} S^2$ , é um estimador enviesado de  $\sigma^2$ . Calcule e comente o respetivo enviesamento.

## Eficiência relativa de estimadores; estimador mais eficiente

Sejam  $T_1 = T_1(\underline{X})$  e  $T_2 = T_2(\underline{X})$  dois estimadores do parâmetro desconhecido  $\theta$ . Então, a eficiência de  $T_1$  - com respeito a  $T_2$  na estimação de  $\theta$  - é dada por

$$e_{\theta}(T_1, T_2) = \frac{EQM_{\theta}(T_2)}{EQM_{\theta}(T_1)}.$$

Assim sendo, se

$$e_{\theta}(T_1, T_2) > 1 \Leftrightarrow EQM_{\theta}(T_2) > EQM_{\theta}(T_1),$$

diremos que o estimador  $T_1$  é mais eficiente que  $T_2$  na estimação de  $\theta$ .

# Conceitos básicos (cont.)

**Exemplo:** Num estudo prévio ao lançamento no mercado de uma nova pilha de *pacemaker* foram colocadas algumas questões acerca da sua duração (em milhares de dias) a um engenheiro. Estudos anteriores (embora com outros tipos de pilhas) levam a crer que tal v.a. possui distribuição uniforme  $(0, \theta)$ , onde o parâmetro  $\theta$  é positivo, desconhecido e representa a idade máxima da pilha.

Calcule a eficiência relativa de  $X_{(n)} = \max\{(X_1, \dots, X_n)\}$  com respeito a  $2\bar{X}$  no que se refere à estimação do parâmetro  $\theta$ . Para o efeito, atente que  $E(X_{(n)}) = \frac{n}{n+1}\theta$  e  $V(X_{(n)}) = \frac{n}{(n+2)(n+1)^2}\theta^2$ . Qual dos dois estimadores de  $\theta$  é mais eficiente?

## V.a. de interesse

$X$  = duração da pilha

## Distribuição

$X \sim \text{uniforme}(0, \theta)$

## Parâmetro desconhecido e espaço paramétrico

$\theta$

$\Theta = \mathbb{R}^+$

**A.a.**

$\underline{X} = (X_1, \dots, X_n)$  a.a. de dimensão  $n$  proveniente da população  $X$

**Estimador de  $\theta$**

$$X_{(n)} = \max\{X_1, \dots, X_n\}$$

**Erro quadrático médio de  $X_{(n)}$**

$$\begin{aligned}EQM_{\theta}(X_{(n)}) &= V(X_{(n)}) + [bias_{\theta}[X_{(n)}]]^2 \\ &= V(X_{(n)}) + [E[X_{(n)}] - \theta]^2 \\ &= \frac{n}{(n+2)(n+1)^2} \theta^2 + \left( \frac{n}{n+1} \theta - \theta \right)^2 \\ &= \frac{2}{(n+2)(n+1)} \theta^2\end{aligned}$$

## Outro estimador de $\theta$

$$2\bar{X}$$

## Erro quadrático médio de $2\bar{X}$

Dado que  $E(\bar{X}) = E(X)$ ,  $V(\bar{X}) = \frac{V(X)}{n}$ ,  $E(X) \stackrel{\text{form.}}{=} \frac{\theta}{2}$  e  $V(X) \stackrel{\text{form.}}{=} \frac{\theta^2}{12}$  temos

$$\begin{aligned}EQM_{\theta}(2\bar{X}) &= V(2\bar{X}) + [bias_{\theta}(2\bar{X})]^2 \\ &= V(2\bar{X}) + [E(2\bar{X}) - \theta]^2 \\ &= \frac{2^2}{n} V(X) + [2E(X) - \theta]^2 \\ &= \frac{2^2}{n} \frac{\theta^2}{12} + \left(2 \times \frac{\theta}{2} - \theta\right)^2 \\ &= \frac{1}{3n} \theta^2\end{aligned}$$

## Eficiência relativa de $X_{(n)}$ com respeito a $2\bar{X}$

$$\begin{aligned}e_{\theta}[X_{(n)}, 2\bar{X}] &= \frac{EQM_{\theta}(2\bar{X})}{EQM_{\theta}(X_{(n)})} \\ &= \frac{\frac{1}{3n}\theta^2}{\frac{2}{(n+2)(n+1)}\theta^2} \\ &= \frac{(n+2)(n+1)}{6n},\end{aligned}$$

que constitui o termo geral de uma sucessão monótona não decrescente, cujos dois primeiros termos são iguais a 1.

### Comentário

Tendo em conta a expressão de  $e_{\theta}[X_{(n)}, 2\bar{X}]$  podemos afirmar que

- $X_{(n)}$  e  $2\bar{X}$  são igualmente eficientes, para  $n = 1, 2$ ,
- $X_{(n)}$  é mais eficiente que  $2\bar{X}$ , para  $n > 2$ .

Curiosamente,  $X_{(n)}$  não é estimador centrado de  $\theta$ , ao contrário de  $2\bar{X}$ .

# Como obter estimadores ou estimativas?

## Como obter estimadores ou estimativas?

Diversos métodos de estimação estão disponíveis:

- Método da máxima verosimilhança
- Método dos momentos
- Método dos mínimos quadrados
- ...

### 3. Método da Máxima Verosimilhança

# Método da Máxima Verosimilhança

O método da máxima verosimilhança é uma técnica usada para estimar parâmetros desconhecidos de um modelo estatístico, a partir de uma amostra observada.

Imagine que você tem dados, mas não sabe exatamente qual é a “melhor” distribuição que os gerou. Suponha que desconfia que os dados vêm de uma distribuição conhecida (como a normal, binomial, Poisson, etc.), mas não conhece os valores dos parâmetros (por exemplo, a média e o desvio padrão no caso da normal).

O que o método da máxima verosimilhança faz é o seguinte:

Escolher os valores dos parâmetros que tornam os dados observados mais prováveis.

Ou seja, dado que já tens os dados, o método pergunta:

“Qual valor do parâmetro mais provavelmente teria gerado exatamente esses dados?”

## Ideia

O parâmetro  $\theta$  é desconhecido, mas  $\underline{x} = (x_1, \dots, x_n)$  são conhecidos. Então, qual é a melhor aproximação para  $\theta$ ? O número que maximiza a probabilidade/densidade de obter a amostra observada. Ou seja, esse valor de  $\theta$  é o mais compatível com os dados observados.

# Método da Máxima Verosimilhança

**Exemplo:** Seja  $X \sim \text{Bernoulli}(p)$ ,  $P(X = 1) = p$  e  $P(X = 0) = 1 - p$ . O parâmetro  $p$  é desconhecido.

**A.a.:**  $(X_1, \dots, X_{10})$ ,  $X_i \stackrel{iid}{\sim} \text{Bern}(p)$

**Amostra particular:**

$$x_1 = x_4 = x_7 = x_8 = x_9 = 0$$

$$x_2 = x_3 = x_5 = x_6 = x_{10} = 1$$

**Função de verosimilhança** desta amostra:

$$\begin{aligned} L(p|x_1, \dots, x_{10}) &= f_X(x_1, p) \times \dots \times f_X(x_{10}, p) \\ &= p^5 \times (1 - p)^5, \quad 0 \leq p \leq 1 \end{aligned}$$

Qual o valor de  $p$  que maximiza  $L$ ?

$$\begin{aligned} \frac{dL}{dp} &= \frac{d(p^5(1-p)^5)}{dp} = 5p^4(1-p)^5 - 5p^5(1-p)^4 \\ &= 5p^4(1-p)^4(1-2p) = 0 \end{aligned}$$

$$\Rightarrow p = 0 \quad \vee \quad p = 1 \quad \vee \quad p = 1/2$$

# Método da Máxima Verosimilhança (cont.)

|      |   |            |     |            |   |
|------|---|------------|-----|------------|---|
| $p$  | 0 |            | 1/2 |            | 1 |
| $L'$ | 0 | +          | 0   | -          | 0 |
| $L$  | 0 | $\nearrow$ | máx | $\searrow$ | 0 |

Portanto a estimativa de **máxima verosimilhança (m.v.)** de  $p$  com base nesta amostra é  $\hat{p} = 1/2$ .

## Definição: Função de verosimilhança

Seja  $X$  uma v.a. com função massa/densidade de probabilidade  $f(x, \theta)$ , onde  $\theta$  é um parâmetro desconhecido. Sejam  $(x_1, \dots, x_n)$  os valores observados de uma a.a. de dimensão  $n$ .

A **função de verosimilhança da amostra** é:

$$L(\theta|x_1, \dots, x_n) = f(x_1, \theta) \times \dots \times f(x_n, \theta) = \prod_{i=1}^n f(x_i, \theta), \quad \theta \in \Theta.$$

A **estimativa de máxima verosimilhança** de  $\theta$  é o valor  $\hat{\theta}$  que maximiza  $L$ . i.e., tal que

$$\hat{\theta} : L(\hat{\theta}|x_1, \dots, x_n) = \max_{\theta \in \Theta} L(\theta|x_1, \dots, x_n).$$

A função de verosimilhança dá ideia de quão plausível é o valor  $\theta$  para o parâmetro desconhecido, caso se tenha recolhido a amostra  $\underline{x}$ .

# Método da Máxima Verosimilhança (cont.)

**Exemplo:** Seja  $X \sim \text{Bern}(p)$ . Sabemos que

$$f_X(x) = P(X = x) = p^x(1-p)^{1-x}, \quad 0 < p < 1.$$

Dada uma amostra  $(x_1, \dots, x_n)$ , temos que

$$\begin{aligned} L(p) &\equiv L(p|x_1, \dots, x_n) \\ &= f_X(x_1) \times \dots \times f_X(x_n) \\ &= \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} \\ &= p^{\sum_{i=1}^n x_i} (1-p)^{\sum_{i=1}^n (1-x_i)} \\ &= p^k (1-p)^{n-k}, \end{aligned}$$

com  $k = \sum_{i=1}^n x_i$  é número de sucessos na amostra e  $n - k$  é o número de insucessos.

## Observação importante

Para uma função  $f > 0$  qualquer,  $f$  e  $\log f$  têm máximo e mínimo nos mesmos pontos (pois  $\log$  é estritamente crescente em  $\mathbb{R}^+$ ). Assim, em vez de determinar  $p$  que **maximiza  $L$**  pode-se determinar  $p$  que **maximiza  $\log L$** , o que envolve cálculos mais simples. A função  $\log L$  é designada por **log-verosimilhança**.

$\log L(\theta|x_1, \dots, x_n)$  – (função de log-verosimilhança)

$\hat{\theta} : \log L(\hat{\theta}|x_1, \dots, x_n) = \max_{\theta \in \Theta} \log L(\theta|x_1, \dots, x_n)$  – (estimativa de MV)

## Exemplo (cont.):

- $\log L(p) = \log(p^k(1-p)^{n-k}) = k \log p + (n-k) \log(1-p)$

$$\Rightarrow \frac{d \log L(p)}{dp} = \frac{k}{p} - \frac{n-k}{1-p} = \frac{k(1-p) - (n-k)p}{p(1-p)} = 0$$

$$\stackrel{p \neq 0,1}{\Rightarrow} k - np = 0 \Rightarrow p = \frac{k}{n} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}$$

- $\frac{d^2 \log L(p)}{dp^2} = -\frac{k}{p^2} - \frac{n-k}{(1-p)^2} < 0, \quad \forall 0 < p < 1$

A **estimativa de m.v.** é  $\hat{p} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}$  (valor numérico).

O **estimador de m.v.** é  $EMV(p) = \hat{P} = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$  (variável aleatória).

## Observações

- O **estimador de MV** de  $\theta$ , denotado por  $EMV(\theta)$ , obtém-se substituindo  $x_1, \dots, x_n$  por  $X_1, \dots, X_n$ , na expressão geral de  $\hat{\theta} =$  **estimativa de MV**.
- **Maximizar  $L \Leftrightarrow$  Maximizar  $\log L$ .**
- Cálculos com  **$\log L$**  são normalmente mais simples do que os cálculos com  $L$ .

# Método da Máxima Verosimilhança (cont.)

## Exemplo: Estimação por MV do parâmetro $\lambda$ da exponencial

Considere-se  $X \sim \text{Exp}(\lambda)$ ,  $\lambda > 0$ ,  $f_X(x) = \lambda e^{-\lambda x}$ ,  $x > 0$ . Dada uma amostra  $(x_1, \dots, x_n)$  a função de verosimilhança é:

$$\begin{aligned}L(\lambda) &\equiv L(\lambda|x_1, \dots, x_n) = f(x_1) \times \dots \times f(x_n) = \prod_{i=1}^n (\lambda e^{-\lambda x_i}) \\ &= \lambda^n e^{-\lambda \sum_{i=1}^n x_i}, \quad \lambda > 0, \quad x_i > 0\end{aligned}$$

$$\log L(\lambda) = n \log \lambda - \lambda \sum_{i=1}^n x_i$$

Determinação do ponto de máximo:

$$\begin{cases} \frac{d \log L(\lambda)}{d\lambda} = 0 \\ \frac{d^2 \log L(\lambda)}{d\lambda^2} < 0 \end{cases} \Leftrightarrow \begin{cases} \frac{n}{\lambda} - \sum_{i=1}^n x_i = 0 \Leftrightarrow n - \lambda \sum_{i=1}^n x_i = 0 \\ -\frac{n}{\lambda^2} < 0, \quad \forall \lambda > 0 \end{cases}$$

A **estimativa de m.v.** de  $\lambda$  é  $\hat{\lambda} = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}}$

O **estimador de m.v.** de  $\lambda$  é  $\Lambda = EMV(\lambda) = \frac{n}{\sum_{i=1}^n X_i} = \frac{1}{\bar{X}}$

## Propriedade de invariância dos estimadores de MV

Se  $EMV(\theta)$  (ou  $\hat{\theta}$ ) é estimador de MV do parâmetro  $\theta$ , então  $g(EMV(\theta))$  é o estimador de MV de  $g(\theta)$ , isto é,

$$EMV(g(\theta)) = g(EMV(\theta)).$$

**Exemplo:** Seja  $X_1, \dots, X_n$  uma a.a. de uma população  $X$  com distribuição  $\text{Exp}(\lambda)$ . Determine o estimador de MV de  $P(X > 2)$ .

$$P(X > 2) = \int_2^{+\infty} f_X(x) dx = \int_2^{+\infty} \lambda e^{-\lambda x} dx = \left[ -e^{-\lambda x} \right]_2^{+\infty} = -e^{-\infty} + e^{-2\lambda} = e^{-2\lambda}$$

$$\Rightarrow EMV(P(X > 2)) = EMV(e^{-2\lambda}) = e^{-2EMV(\lambda)} = e^{-2/\bar{X}}.$$

**Exemplo:** Considere uma urna com bolas brancas e pretas na proporção de 3/1 desconhecendo-se, no entanto, qual a cor dominante. Seja  $p$  a probabilidade de sair uma bola preta numa extração.

Qual é a estimativa de MV de  $p$  se, ao extrairmos com reposição três bolas da urna, encontrássemos

- (a) uma bola preta?
- (b) duas bolas pretas?

# Método da Máxima Verosimilhança (cont.)

## V.a. de interesse

$X$  = indicador de extração de bola preta

$$= \begin{cases} 1, & \text{se sair bola preta} \\ 0, & \text{se sair bola branca} \end{cases}$$

## Distribuição de $X$

$X \sim \text{Bernoulli}(p)$

## F.m.p de $X$

$$P(X = x) = p^x(1 - p)^{1-x}, \quad x = 0, 1$$

## Parâmetro desconhecido e espaço paramétrico

$$p = P(X = 1) = P(\text{sair bola preta})$$

Uma vez que a urna possui bolas brancas e pretas na proporção de 3 para 1, o conjunto de valores possíveis de  $p$  é  $\Theta = \{\frac{1}{4}, \frac{3}{4}\}$ .

Com efeito:  $p = \frac{1}{4}$ , se houver 3 vezes mais bolas brancas que pretas;  $p = \frac{3}{4}$ , se houver 4 vezes mais bolas pretas que brancas.



## Amostra

Lidamos com  $\underline{x} = (x_1, \dots, x_n)$ , uma amostra de dimensão  $n$  proveniente da população  $X$ . Em particular,

$$\underline{x} : n = 3$$

$$\sum_{i=1}^3 x_i = \text{número de bolas pretas nas 3 extrações} = \begin{cases} (a) & 1 \text{ bola preta} \\ (b) & 2 \text{ bolas pretas} \end{cases}$$

## Obtenção da estimativa de MV de $p$

Será representada por  $\hat{p}$  e  $L(\hat{p}|\underline{x}) = \max_{p \in \Theta} L(p|\underline{x})$ , onde  $L(p|\underline{x})$  representa a função de verosimilhança. Assim,  $\hat{p}$  é o valor mais plausível/verosímil para o parâmetro desconhecido  $p$ , tendo em conta a amostra  $\underline{x}$ .

## Função de verosimilhança

$$\begin{aligned}L(p|\underline{x}) &= P(\underline{X} = \underline{x}) \\ &\stackrel{X_i \text{ indep}}{=} \prod_{i=1}^n P(X_i = x_i) \\ &\stackrel{X_i \sim X}{=} \prod_{i=1}^n P(X = x_i) \\ &= \prod_{i=1}^n [p^{x_i} (1-p)^{1-x_i}] \\ &\stackrel{n=3}{=} p^{\sum_{i=1}^3 x_i} (1-p)^{3-\sum_{i=1}^3 x_i}, \quad p \in \Theta = \left\{ \frac{1}{4}, \frac{3}{4} \right\}\end{aligned}$$

## Maximização e concretização

Dado que  $\Theta$  é um conjunto discreto, não devemos recorrer à técnica usual de maximização que passa por calcular a função de log-verosimilhança, a 1a e 2a derivadas de  $\ln L(p|\underline{x})$ , resolver a equação de verosimilhança, etc.

De facto, a estimativa de MV de  $p$  obtém-se calculando os vários valores de  $L(p|\underline{x})$ , para  $p \in \Theta$ , e identificando o ponto de máximo - ou seja, faz-se por pesquisa ponto por ponto.

# Método da Máxima Verosimilhança (cont.)

| $L(p   \underline{x})$ | $\sum_{i=1}^3 x_i = 1$                  | $\sum_{i=1}^3 x_i = 2$                  |
|------------------------|---|---|
| $p = \frac{1}{4}$      | $(1/4)^1(1 - 1/4)^{3-1} = \frac{9}{64}$ | $(1/4)^2(1 - 1/4)^{3-2} = \frac{3}{64}$ |
| $p = \frac{3}{4}$      | $(3/4)^1(1 - 3/4)^{3-1} = \frac{3}{64}$ | $(3/4)^2(1 - 3/4)^{3-2} = \frac{9}{64}$ |

A inspeção da tabela anterior leva a concluir que

$$\hat{p} = \begin{cases} \text{(a) } \frac{1}{4}, & \text{se } \sum_{i=1}^3 x_i = 1 \text{ (bola preta), pois } L\left(\frac{1}{4} | \underline{x}\right) > L\left(\frac{3}{4} | \underline{x}\right) \\ \text{(b) } \frac{3}{4}, & \text{se } \sum_{i=1}^3 x_i = 2 \text{ (bolas pretas), já que } L\left(\frac{3}{4} | \underline{x}\right) > L\left(\frac{1}{4} | \underline{x}\right) \end{cases}$$

# Método da Máxima Verosimilhança (cont.)

## O estimador de MV pode não ser único...

Suponha que  $X_1, \dots, X_n$  é uma amostra aleatória de uma distribuição uniforme no intervalo  $(\theta, \theta + 1)$ , e o valor do parâmetro  $\theta$  é desconhecido ( $-\infty < \theta < +\infty$ ). Qual o estimador de MV de  $\theta$ ?

A f.d.p de  $X$  é  $f_X(x) = \begin{cases} 1, & \theta \leq x \leq \theta + 1 \\ 0, & \text{caso contrário.} \end{cases}$  A função de verosimilhança é:

$$L(\theta) = \begin{cases} 1, & \theta \leq x_i \leq \theta + 1 \quad (i = 1, \dots, n) \\ 0, & \text{caso contrário.} \end{cases}$$

A condição que  $\theta \leq x_i$  para  $i = 1, \dots, n$  é equivalente à condição que  $\theta \leq \min(x_1, \dots, x_n)$ . Analogamente, a condição que  $x_i \leq \theta + 1$  para  $i = 1, \dots, n$  é equivalente à condição que  $\theta \geq \max(x_1, \dots, x_n) - 1$ . Então, podemos reescrever a função de verosimilhança da forma:

$$L(\theta) = \begin{cases} 1, & \max(x_1, \dots, x_n) - 1 \leq \theta \leq \min(x_1, \dots, x_n) \\ 0, & \text{caso contrário.} \end{cases}$$

Assim, podemos selecionar qualquer valor no intervalo  $[\max(x_1, \dots, x_n) - 1, \min(x_1, \dots, x_n)]$  como estimativa de MV para  $\theta$ . Então, estimador de MV não é unicamente especificado neste exemplo.

- Manuel Cabral Morais (2020): Probabilidade e Estatística: Teoria, Exemplos & Exercícios. IST Press, 1a edição.