

# Estatística II

## Estimação Paramétrica

Matemática e Física ◦ 1º semestre 2006 ◦ Turma 4M

Wagner de Souza Borges

FCBEE, Universidade Presbiteriana Mackenzie

wborges@mackenzie.com.br

### Introdução

No cálculo de probabilidades vimos que as probabilidades de eventos definidos através de uma característica observável no resultado de um *processo aleatório*  $\Psi$  são calculadas a partir da *distribuição de probabilidades* da *variável aleatória* que representa essa característica. Veremos agora, de que maneira os valores de uma *variável aleatória*, observada em *ensaios repetidos* de um *processo aleatório*  $\Psi$  pode ser utilizada para fazer um prognóstico acerca de um objeto desconhecido  $\xi$ , de natureza numérica, relacionado com a *distribuição de probabilidades* dessa *variável aleatória*, ao qual daremos o nome de *parâmetro*. Esse problema será tratado aqui sob o nome de *estimação paramétrica*.

Para introduzir de maneira simples alguns conceitos importantes da estimação paramétrica, considere o seguinte exemplo.

**Exemplo 1.** Suponha que você está interessado em determinar a probabilidade de cara  $\xi$  de uma moeda. A coisa mais intuitiva que nos ocorre numa situação como esta é arremessar a moeda um certo número de vezes, e observar o que acontece. Digamos que você tenha arremessado a moeda, de forma independente e sob as mesmas condições, 13 vezes e tenha observado o seguinte resultado:

*cara, coroa, coroa, cara, cara, coroa, cara,*  
*cara, coroa, cara, coroa, coroa, cara.*

Com base neste resultado, um prognóstico para o *parâmetro*  $\xi$  é a

$$\text{proporção observada de caras nos 13 arremessos} = \frac{7}{13}.$$

Representando *cara* por 1 e *coroa* por 0, o resultado obtido, nos 13 arremessos,

(1, 0, 0, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1),

nada mais é do que o conjunto das observações das *variáveis aleatórias*

$$X_1, X_2, X_3, \dots, X_{13},$$

em que  $X_i$  é o *número de caras* observado no  $i$ -ésimo arremêso da moeda,  $i = 1, 2, \dots, 13$ .

Nas condições em que os arremessos foram executados, podemos admitir que essas *variáveis aleatórias* são independentes e identicamente distribuídas (IID) com função de probabilidade

$$f(x; \xi) = \xi^x(1 - \xi)^{1-x}, \quad x = 0, 1 \text{ e } 0 \leq \xi \leq 1.$$

**Observação 1.1.1.** Lembre que a expressão acima admite a seguinte forma tabular:

$x$	$P\{X = x\}$
0	$1 - \xi$
1	$\xi$

Nessas condições, diz-se que

$$X_1, X_2, X_3, \dots, X_{13},$$

é uma *amostra casual simples* (ACS) da distribuição  $f(x; \xi)$ . Diz-se ainda que o conjunto de dados

$$(1, 0, 0, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1),$$

é a ACS *observada* da distribuição  $f(x; \xi)$  e que o prognóstico  $\frac{7}{13}$  para a *probabilidade de cara*,  $\xi$ , da moeda, é uma *estimativa* desse *parâmetro*.

**Observação 2.** Note que a *estimativa* de  $\xi$  é obtida substituindo-se na expressão

$$\frac{X_1 + X_2 + \dots + X_{13}}{13}$$

os valores observados

$$x_1 = 1, x_2 = 0, x_3 = 0, x_4 = 1, \dots, x_{12} = 0, x_{13} = 1$$

de  $X_1, X_2, \dots, X_{13}$ . Por esse motivo, diz-se que

$$T(X_1, X_2, \dots, X_{13}) = \frac{X_1 + X_2 + \dots + X_{13}}{13}$$

é o estimador de  $\xi$ .

△

No **Exemplo 1**, três conceitos básicos foram estabelecidos. São eles: o de *amostra casual simples*, o de *estimativa* e o de *estimador*. Mais precisamente, tem-se:

### Amostra Casual Simples

Diz-se que um conjunto de dados

$$x_1, x_2, \dots, x_n$$

é uma amostra casual simples (ACS) observada de uma distribuição de probabilidades  $f(x; \theta)$  quando ele é constituído pelos valores observados das *variáveis aleatórias*

$$X_1, X_2, X_3, \dots, X_n,$$

independentes e identicamente distribuídas (IID), com distribuição de probabilidades  $f(x; \theta)$ .

**Observação 1.2.1.** O termo *amostra casual simples* será aplicado também em referência a  $\mathbf{X}$ .

**Observação 1.2.2.** Serão tratados apenas conjuntos de dados reais univariados.

**Observação 1.2.3.** A distribuição de probabilidades  $f(x; \theta)$  será sempre expressa por uma função de probabilidades (componentes de  $\mathbf{X}$  discretas) ou por uma função densidade de probabilidades (componentes de  $\mathbf{X}$  contínuas). O símbolo  $\theta$  representa um escalar ou um vetor real que, se conhecido, especifica completamente tanto a distribuição de probabilidades de  $X$  quanto o parâmetro de interesse  $\xi$ .

△

### Definição 1.3: Estimativa.

Uma estimativa para um parâmetro de interesse  $\xi$  é um prognóstico do seu valor desconhecido obtido através de uma função,

$$(x_1, x_2, \dots, x_n) \mapsto T(x_1, x_2, \dots, x_n),$$

dos dados disponíveis.

△

### Definição 1.3: Estimador.

Se a estimativa para um parâmetro de interesse  $\xi$  é obtida através da função

$$(x_1, x_2, \dots, x_n) \mapsto T(x_1, x_2, \dots, x_n),$$

dos dados disponíveis, diz-se que a variável ou vetor aleatório

$$T(\mathbf{X}) = T(X_1, X_2, \dots, X_n)$$

é um estimador de  $\xi$ .

△

# 1 Estimativas de Máxima Verossimilhança

**Exemplo 2.1.** Nas condições do **Exemplo 1.1**, não é difícil ver que a *estimativa*

$$T(x_1, x_2, \dots, x_{13}) = \frac{x_1 + x_2 + \dots + x_{13}}{13} = \frac{7}{13}$$

de  $\xi$  maximiza a

$$\begin{aligned} P\{X_1 = x_1, \dots, X_{13} = x_{13}\} &= \prod_{i=1}^{13} f(x_i; \xi) \\ &= \prod_{i=1}^{13} \xi^{x_i} (1 - \xi)^{1-x_i} \\ &= \xi^{x_1+x_2+\dots+x_{13}} (1 - \xi)^{13-(x_1+x_2+\dots+x_{13})}, \end{aligned}$$

isto é,

$$\frac{7}{13} = \frac{x_1 + x_2 + \dots + x_{13}}{13} \in \operatorname{argmax}\{L(\xi) : 0 \leq \xi \leq 1\},$$

em que

$$\begin{aligned} L(\xi) &= \xi^{x_1+x_2+\dots+x_{13}} (1 - \xi)^{13-(x_1+x_2+\dots+x_{13})} \\ &= \xi^7 (1 - \xi)^6, \quad 0 \leq \xi \leq 1. \end{aligned}$$

Por esse motivo diz-se que essa *estimativa* é de *máxima verossimilhança*. A função  $L(\xi)$ ,  $0 \leq \xi \leq 1$ , é denominada função de verossimilhança da amostra (ou dos dados).

△

Definição 2.2: Estimativas de Máxima Verossimilhança.

Se  $(x_1, x_2, \dots, x_n)$  é uma ACS de uma distribuição  $f(x; \theta)$ , diz-se que uma estimativa  $T(x_1, x_2, \dots, x_n)$  de  $\theta$ , é de *máxima verossimilhança* se

$$T(x_1, x_2, \dots, x_n) \in \operatorname{argmax}\{L(\theta); \theta \in \Theta\}$$

em que

$$L(\theta) = \prod_{i=1}^n f(x_i; \theta).$$

Para distingui-la, representa-se essa *estimativa* por

$$\hat{\theta}(x_1, x_2, \dots, x_n)$$

ao invés de  $T(x_1, x_2, \dots, x_n)$ . A variável ou vetor aleatório definido por

$$\hat{\theta}(X_1, X_2, \dots, X_n),$$

é denominado *estimador de máxima verossimilhança* de  $\theta$ .

**Observação 2.2.1.** A função  $L(\theta)$  definida acima é denominada *função de verossimilhança* da amostra (ou dos dados).

**Observação 2.2.2.**  $\operatorname{argmax}\{L(\theta); \theta \in \Theta\}$  é conjunto dos valores de  $\theta \in \Theta$  que maximizam  $L(\theta)$ .

**Observação 2.2.3.** A função

$$\begin{aligned} l(\theta) &= \ln L(\theta), \\ &= \sum_{i=1}^n \ln f(x_i; \theta), \quad \theta \in \Theta, \end{aligned}$$

é denominada *função score* da amostra (ou dos dados).

**Observação 2.2.4.**  $\operatorname{argmax}\{L(\theta); \theta \in \Theta\} = \operatorname{argmax}\{l(\theta); \theta \in \Theta\}$ .

**Observação 2.2.5.** Se o parâmetro  $\xi$  a ser estimado é uma função de  $\theta$ , isto é,

$$\xi = g(\theta), \quad \theta \in \Theta,$$

a *estimativa de máxima verossimilhança* de  $\xi$  é dada por

$$\hat{\xi}(x_1, x_2, \dots, x_n) = g(\hat{\theta}(x_1, x_2, \dots, x_n)).$$

O *estimador de máxima verossimilhança* de  $\xi$ , neste caso, é

$$\hat{\xi}(X_1, X_2, \dots, X_n) = g(\hat{\theta}(X_1, X_2, \dots, X_n)).$$

△

**Exemplo 2.3.** Suponha que o tempo de duração de um componente eletrônico é uma variável aleatória com distribuição exponencial com parâmetro  $\lambda > 0$  desconhecido. Qual a *estimativa de máxima verossimilhança* do tempo médio de duração  $\xi$  desse componente se a soma das durações observadas de 10 componentes colocadas em teste foi de 7350 horas?

Sejam  $x_1, x_2, \dots, x_{10}$  as durações observadas dessas componentes. Admitindo que elas foram testadas independentemente sob as mesmas condições, essas observações constituem uma ACS de tamanho 10 da distribuição de probabilidades

$$f(x; \lambda) = \lambda e^{-\lambda x}, \quad x \geq 0 \text{ e } \lambda > 0.$$

Como tempo médio de duração  $\xi$  desse componente é igual a  $\frac{1}{\lambda}$ , sua *estimativa de máxima verossimilhança* é dada por

$$\hat{\xi}(x_1, x_2, \dots, x_{10}) = \frac{1}{\hat{\lambda}(x_1, x_2, \dots, x_{10})},$$

em que

$$\hat{\lambda}(x_1, x_2, \dots, x_{10}) \in \operatorname{argmax}\{l(\lambda) : \lambda > 0\}.$$

e

$$\begin{aligned}l(\lambda) &= \ln\left(\prod_{i=1}^{10} \lambda e^{-\lambda x_i}\right) \\&= \ln(\lambda^{10} e^{-\lambda \sum_{i=1}^{10} x_i}) \\&= 10 \ln \lambda - \lambda \sum_{i=1}^{10} x_i, \quad \lambda > 0.\end{aligned}$$

Portanto,

$$\operatorname{argmax}\{l(\lambda) : \lambda > 0\} = \{\lambda > 0 : \frac{10}{\lambda} = \sum_{i=1}^{10} x_i\}$$

e

$$\begin{aligned}\hat{\xi}(x_1, x_2, \dots, x_{10}) &= \frac{1}{\hat{\lambda}(x_1, x_2, \dots, x_{10})} \\&= \frac{1}{\frac{10}{x_1 + x_2 + \dots + x_{10}}} \\&= \frac{x_1 + x_2 + \dots + x_{10}}{10}.\end{aligned}$$

Portanto, a *estimativa de máxima verossimilhança* do tempo médio de duração desse componente,  $\xi$ , é

$$\frac{x_1 + x_2 + \dots + x_{10}}{10} = \frac{7350}{10} = 735 \text{ horas.}$$

△

## 2 Vício, Consistência e Eficiência

Definição 3.1: Vício.

Sejam:  $(x_1, x_2, \dots, x_n)$  uma ACS de uma distribuição  $f(x; \theta)$ ,  $\theta \in \Theta$ ;  $T(X_1, X_2, \dots, X_n)$  um *estimador* de  $\xi = g(\theta) \in \Xi \subset \Re$ ; e

$$\mu_T(\theta) = E(T(X_1, X_2, \dots, X_n)).$$

Diz-se que  $T$  é *não viciado* se

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

para todo  $\theta \in \Theta$ .

△

Exemplo 3.2. No **Exemplo 1.1** O *estimador* de  $\xi$  é *não viciado*.

△

Definição 3.3: Consistência.

Sejam:  $(x_1, x_2, \dots, x_n)$  uma ACS de uma distribuição  $f(x; \theta)$ ,  $\theta \in \Theta$ ;  $T(X_1, X_2, \dots, X_n)$  um *estimador* de  $\xi = g(\theta) \in \Xi \subset \mathfrak{R}$ ; e

$$\sigma_T^2(\theta) = \text{Var}(T(X_1, X_2, \dots, X_n)).$$

Diz-se que  $T$  é *consistente* se

$$\lim_{n \rightarrow \infty} \sigma_T^2(\theta) = 0$$

para todo  $\theta \in \Theta$  .

Exemplo 3.4. No **Exemplo 1.1** O *estimador* de  $\xi$  é *consistente*.

△

Definição 3.5: Eficiência.

Sejam:  $(x_1, x_2, \dots, x_n)$  uma ACS de uma distribuição  $f(x; \theta)$ ,  $\theta \in \Theta$ ; e  $T_1(X_1, X_2, \dots, X_n)$  e  $T_2(X_1, X_2, \dots, X_n)$  dois *estimadores não viciados* de  $\xi = g(\theta) \in \Xi \subset \mathfrak{R}$ . Diz-se que  $T_1$  é *mais eficiente* que  $T_2$  se

$$\sigma_{T_1}^2(\theta) \leq \sigma_{T_2}^2(\theta) ,$$

para todo  $\theta \in \Theta$  , e

$$\sigma_{T_1}^2(\theta_0) < \sigma_{T_2}^2(\theta_0)$$

para algum  $\theta_0 \in \Theta$  .