

1ª) Demonstre que as seguintes distribuições pertencem à Família Exeponencial:

a)  $X \sim Gama(r, \lambda)$  (analise em função de  $\lambda$ ):

**Resposta**

$$\begin{aligned} f_X(x) &= \frac{\lambda^r}{\Gamma(r)} \exp\{-\lambda x\} \mathbb{I}_{(0, \infty)}(x) \\ &= \exp\{r \log(\lambda) - \log[\Gamma(r)] - \lambda x\} \mathbb{I}_{(0, \infty)}(x) \\ &= h(x) \exp\{\eta(\theta)T(x) - B(\theta)\}, \end{aligned}$$

com  $h(x) = \mathbb{I}_{(0, \infty)}(x)$ ,  $\eta(\theta) = -\lambda$ ,  $T(x) = x$ ,  $B(\theta) = \log[\Gamma(r)] - r \log(\lambda)$ .

b)  $X \sim Beta(a, b)$ :

**Resposta**

$$\begin{aligned} f_X(x) &= \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} x^{a-1}(1-x)^{b-1} \mathbb{I}_{(0,1)}(x) \\ &= \exp\{\log(\Gamma(a+b)) - \log(\Gamma(a)) - \log(\Gamma(b)) + (a-1)\log x + (b-1)\log(1-x)\} \mathbb{I}_{(0,1)}(x) \\ &= h(x) \exp\left\{\sum_{i=1}^2 \eta_i(\boldsymbol{\theta})T_i(x) - B(\boldsymbol{\theta})\right\}, \end{aligned}$$

com  $h(x) = \mathbb{I}_{(0,1)}(x)$ ,  $\eta_1(\boldsymbol{\theta}) = (a-1)$ ,  $\eta_2(\boldsymbol{\theta}) = (b-1)$ ,  $T_1(x) = \log x$ ,  $T_2(x) = \log(1-x)$ ,  $B(\boldsymbol{\theta}) = \log(\Gamma(a)) + \log(\Gamma(b)) - \log(\Gamma(a+b))$ .

2ª) Seja  $X_1, \dots, X_n$  uma amostra aleatória de

$$f_X(x) = e^{-(x-\theta)} \mathbb{I}_{\theta, \infty}(x), \quad -\infty < \theta < \infty,$$

ache uma estatística suficiente para  $\theta$ .

**Resposta**

A distribuição conjunta da amostra é dada por

$$f_{\mathbf{X}}(\mathbf{x}) = \prod_{i=1}^n e^{-(x_i-\theta)} \mathbb{I}_{(\theta, \infty)}(x_i) = e^{-(\sum_{i=1}^n x_i - n\theta)} \mathbb{I}_{(\theta, \infty)}(x_{(1)}) \mathbb{I}_{(x_{(1)}, \infty)}(x_{(n)}),$$

pois  $\theta < x_i < \infty \forall i = 1, \dots, n \Leftrightarrow \theta < x_{(1)} < x_{(n)} < \infty$ , com  $X_{(1)} = \min\{X_1, \dots, X_n\}$  e  $X_{(n)} = \max\{X_1, \dots, X_n\}$ . Então,

$$f_{\mathbf{X}}(\mathbf{x}) = e^{-\sum_{i=1}^n x_i} e^{n\theta} \mathbb{I}_{(\theta, \infty)}(x_{(1)}) \mathbb{I}_{(x_{(1)}, \infty)}(x_{(n)}) = g(x_{(1)}, \theta) h(\mathbf{x}),$$

com  $g(x_{(1)}, \theta) = e^{n\theta} \mathbb{I}_{(\theta, \infty)}(x_{(1)})$  e  $h(\mathbf{x}) = e^{-\sum_{i=1}^n x_i} \mathbb{I}_{(x_{(1)}, \infty)}(x_{(n)})$ , ou seja,  $g(x_{(1)}, \theta)$  só depende da amostra através da estatística  $X_{(1)}$ , assim pelo Teorema da Fatoração  $X_{(1)}$  é uma estatística suficiente para  $\theta$ .

3ª) Seja  $X$  uma única observação de uma  $N(0, \theta)$ . ( $\theta = \sigma^2$ .)

a)  $X$  é uma estatística suficiente?

**Resposta**

Sim, pois a amostra é sempre suficiente para o parâmetro.

b)  $|X|$  é uma estatística suficiente?

**Resposta**

A densidade conjunta da amostra com uma única observação é dada por

$$f_X(x) = \frac{1}{\sqrt{2\pi\theta}} \exp\left\{-\frac{x^2}{2\theta}\right\} \mathbb{I}_{\mathbb{R}}(x) = g(x^2, \theta) h(x),$$

com  $g(x^2, \theta) = \frac{1}{\sqrt{2\pi\theta}} \exp\left\{-\frac{x^2}{2\theta}\right\}$  e  $h(x) = \mathbb{I}_{\mathbb{R}}(x)$ , como  $g(x^2, \theta)$  só depende da amostra através de  $X^2$ , então pelo Teorema da Fatoração esta é uma estatística suficiente. Fazendo  $g(X^2) = \sqrt{X^2} = |X|$ , sendo  $g(\cdot)$  uma função 1 a 1 de  $X^2$ , ou seja, uma função 1 a 1 de uma estatística suficiente, temos que  $|X|$  também é uma estatística suficiente para  $\theta$ .

4ª) Considere  $X$  com densidade  $f_X(x) = (\theta/2)^{|x|}(1-\theta)^{1-|x|}\mathbb{I}_{\{-1,0,1\}}(x)$ ,  $0 \leq \theta \leq 1$ . Defina  $t(x) = 2\mathbb{I}_{\{1\}}(x)$ .

a)  $X$  é uma estatística suficiente?

**Resposta**

Sim, pois a amostra é sempre uma estatística suficiente para o parâmetro.

b)  $|X|$  é uma estatística suficiente?

**Resposta**

A densidade conjunta para uma única amostra é dada por

$$\begin{aligned} f_X(x) &= (\theta/2)^{|x|}(1-\theta)^{1-|x|}\mathbb{I}_{\{-1,0,1\}}(x) = (\theta/2)^{|x|} \frac{(1-\theta)}{(1-\theta)^{|x|}} \mathbb{I}_{\{-1,0,1\}}(x) \\ &= \left(\frac{\theta}{2(1-\theta)}\right)^{|x|} (1-\theta) \mathbb{I}_{\{-1,0,1\}}(x) = g(|x|, \theta)h(x), \end{aligned}$$

com  $g(|x|, \theta) = \left(\frac{\theta}{2(1-\theta)}\right)^{|x|} (1-\theta)$  e  $h(x) = \mathbb{I}_{\{-1,0,1\}}(x)$ . Como  $g(|x|, \theta)$  só depende da amostra através da estatística  $|X|$ , então pelo Teorema da Fatoração ela é uma estatística suficiente.

c) Qual é o estimador de máxima verossimilhança de  $\theta$ ?

**Resposta**

A log-verossimilhança da distribuição para uma amostra com única observação é dada por

$$l(\theta) = |x|(\log(\theta) - \log 2) + (1 - |x|) \log(1 - \theta),$$

calculando o estimador de verossimilhança, temos que

$$\begin{aligned} \frac{\partial l(\theta)}{\partial \theta} &= \frac{|x|}{\theta} - \frac{(1-|x|)}{1-\theta}; \\ \frac{\partial l(\theta)}{\partial \theta} = 0 &\Rightarrow \frac{|x|}{\hat{\theta}_{mv}} - \frac{(1-|x|)}{1-\hat{\theta}_{mv}} = 0 \\ &\Rightarrow \hat{\theta}_{mv} - \hat{\theta}_{mv}|x| = |x| - |x|\hat{\theta}_{mv} \Rightarrow \hat{\theta}_{mv} = |x|; \\ \frac{\partial^2 l(\theta)}{\partial \theta^2} &= -\frac{|x|}{\theta^2} - \frac{(1-|x|)}{(1-\theta)^2} < 0, \text{ para } x \in \{-1, 0, 1\}. \end{aligned}$$

Assim a estatística  $|X|$  é o EMV para  $\theta$ .

d)  $T = t(x)$  é um estimador não viesado para  $\theta$ ?

**Resposta**

Como  $T = t(x) = 2\mathbb{I}_{\{1\}}(x)$ , com

$$\mathbb{I}_{\{1\}}(x) = \begin{cases} 1, & \text{com } \mathbb{P}(X = 1), \\ 0, & \text{com } \mathbb{P}(X \neq 1) \end{cases}$$

assim,

$$\mathbb{E}(T) = 2\mathbb{P}(X = 1) = 2\frac{\theta}{2} = \theta.$$

Portanto,  $T$  é um estimador não-viesado para  $\theta$

e)  $f_X(x)$  pertence à Família Exponencial?

**Resposta**

$$\begin{aligned} f_X(x) &= \exp\{|x| \log(\theta) + (1 - |x|) \log(1 - \theta)\} \frac{1}{2^{|x|}} \mathbb{I}_{\{-1,0,1\}}(x) \\ &= \exp\left\{|x| \log\left(\frac{\theta}{1-\theta}\right) + \log(1-\theta)\right\} \frac{1}{2^{|x|}} \mathbb{I}_{\{-1,0,1\}}(x) \\ &= \exp\{\eta(\theta)T(x) - B(\theta)\}h(x), \end{aligned}$$

com  $\eta(\theta) = \log\left(\frac{\theta}{1-\theta}\right)$ ,  $T(x) = |x|$ ,  $B(\theta) = -\log(1-\theta)$  e  $h(x) = \frac{1}{2^{|x|}} \mathbb{I}_{\{-1,0,1\}}(x)$ , além disso, o suporte da distribuição não depende do parâmetro. Portanto  $f_X(x)$  pertence a Família Exponencial uniparamétrica.

5ª) Seja  $X_1, \dots, X_n$  uma amostra aleatória da densidade

$$f_X(x) = \theta x^{-2} \mathbb{I}_{[\theta, \infty)}(x),$$

com  $\theta > 0$ .

a) Ache o estimador de máxima verossimilhança de  $\theta$ .

**Resposta**

A densidade conjunta da amostra é dada por

$$f_{\mathbf{X}}(\mathbf{x}) = \prod_{i=1}^n \theta x_i^{-2} \mathbb{I}_{[\theta, \infty)}(x_i) = \theta^n \prod_{i=1}^n x_i^{-2} \mathbb{I}_{[\theta, \infty)}(x_{(1)}) \mathbb{I}_{[x_{(1)}, \infty)}(x_{(n)})$$

pois  $\theta < x_i < \infty \forall i = 1, \dots, n \Leftrightarrow \theta < x_{(1)} < x_{(n)} < \infty$ , com  $X_{(1)} = \min\{X_1, \dots, X_n\}$  e  $X_{(n)} = \max\{X_1, \dots, X_n\}$ . A verossimilhança fica dada então por

$$L(\theta) \propto \theta^n \mathbb{I}_{(0, x_{(1)})},$$

pois  $0 < \theta \leq x_{(1)} < x_{(n)} < \infty$ , então  $0 < \theta \leq x_{(1)}$ .  $L(\theta)$  é máxima quando  $\theta = x_{(1)}$ , pois  $L(x_{(1)}) > L(\theta)$ ,  $\forall \theta \in (0, x_{(1)})$ . Então, como  $X_{(1)}$  maximiza a verossimilhança,  $\hat{\theta}_{mv} = X_{(1)}$ .

b) A estatística  $X_{(1)} = \min\{X_1, \dots, X_n\}$ ?

**Resposta**

Os estimadores de máxima verossimilhança sempre dependem da amostra somente através de estatísticas suficientes, ou seja, são funções de estatísticas suficientes. Como o estimador de máxima verossimilhança obtido no item b) é a estatística  $X_{(1)}$  então esta é suficiente, como consequência.

6ª) Para cada distribuição abaixo seja  $X_1, \dots, X_n$  uma amostra aleatória. Ache uma estatística suficiente minimal para  $\theta$ .

a)  $f_X(x) = \frac{1}{\sqrt{2\pi}} e^{-(x-\theta)^2/2} \mathbb{I}_{(\mathbb{R})}(x)$ ,  $-\infty < \theta < \infty$ .

**Resposta**

Fazendo uma razão de densidades conjuntas para as amostras  $X_1, \dots, X_n$  e  $Y_1, \dots, Y_n$  ambas providas da mesma distribuição, temos que

$$\begin{aligned} \frac{f_{\mathbf{X}}(\mathbf{x})}{f_{\mathbf{X}}(\mathbf{y})} &= \frac{\frac{1}{(\sqrt{2\pi})^n} e^{-\sum_{i=1}^n (x_i - \theta)^2/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{x})}{\frac{1}{(\sqrt{2\pi})^n} e^{-\sum_{i=1}^n (y_i - \theta)^2/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{y})} = \frac{e^{-(\sum_{i=1}^n x_i^2 - 2\theta \sum_{i=1}^n x_i + n\theta^2)/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{x})}{e^{-(\sum_{i=1}^n y_i^2 - 2\theta \sum_{i=1}^n y_i + n\theta^2)/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{y})} \\ &= \frac{e^{-(\sum_{i=1}^n x_i^2 - 2\theta \sum_{i=1}^n x_i)/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{x})}{e^{-(\sum_{i=1}^n y_i^2 - 2\theta \sum_{i=1}^n y_i)/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{y})}, \end{aligned}$$

a única forma dessa razão não depender de  $\theta$ , ou seja, ser constante em relação à  $\theta$ , é se  $\sum_{i=1}^n x_i = \sum_{i=1}^n y_i$ , pois os termos multiplicados por  $\theta$  se cancelariam e obteríamos,

$$\frac{f_{\mathbf{X}}(\mathbf{x})}{f_{\mathbf{X}}(\mathbf{y})} = \frac{e^{-(\sum_{i=1}^n x_i^2)/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{x})}{e^{-(\sum_{i=1}^n y_i^2)/2} \mathbb{I}_{\mathbb{R}^n}(\mathbf{y})}.$$

Então, pelo Teorema sobre estatística suficientes e minimais,  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  é uma estatística suficiente e minimal para  $\theta$ .

b)  $f_X(x) = e^{-(x-\theta)} \mathbb{I}_{(\theta, \infty)}(x)$ ,  $-\infty < \theta < \infty$ .

**Resposta**

Da mesma forma que o item anterior, faremos a razão de densidades conjuntas para as amostras  $X_1, \dots, X_n$  e  $Y_1, \dots, Y_n$  ambas providas da mesma distribuição, então, temos que

$$\begin{aligned} \frac{f_{\mathbf{X}}(\mathbf{x})}{f_{\mathbf{X}}(\mathbf{y})} &= \frac{e^{-\sum_{i=1}^n (x_i - \theta)} \prod_{i=1}^n \mathbb{I}_{(\theta, \infty)}(x_i)}{e^{-\sum_{i=1}^n (y_i - \theta)} \prod_{i=1}^n \mathbb{I}_{(\theta, \infty)}(y_i)} = \frac{e^{-(n\bar{x} - n\theta)} \mathbb{I}_{(\theta, \infty)}(x_{(1)}) \mathbb{I}_{(x_{(1)}, \infty)}(x_{(n)})}{e^{-(n\bar{y} - n\theta)} \mathbb{I}_{(\theta, \infty)}(y_{(1)}) \mathbb{I}_{(y_{(1)}, \infty)}(y_{(n)})} \\ &= \frac{e^{-n\bar{x}} \mathbb{I}_{(\theta, \infty)}(x_{(1)}) \mathbb{I}_{(x_{(1)}, \infty)}(x_{(n)})}{e^{n\bar{y}} \mathbb{I}_{(\theta, \infty)}(y_{(1)}) \mathbb{I}_{(y_{(1)}, \infty)}(y_{(n)})}, \end{aligned}$$

com  $X_{(1)} = \min\{X_1, \dots, X_n\}$ ,  $X_{(n)} = \max\{X_1, \dots, X_n\}$ ,  $Y_{(1)} = \min\{Y_1, \dots, Y_n\}$  e  $Y_{(n)} = \max\{Y_1, \dots, Y_n\}$ . Para que a razão seja constante em relação à  $\theta$ , é preciso que  $x_{(1)} = y_{(1)}$ , pois assim o termo que depende de  $\theta$  (os indicadores) se cancelariam. Então pelo Teorema,  $T(\mathbf{X}) = X_{(1)}$  é uma estatística suficiente e minimal para  $\theta$ .

- 7<sup>a</sup>) Seja  $X_1, \dots, X_n$  uma amostra aleatória de uma distribuição uniforme no intervalo  $(\theta, 2\theta)$ ,  $\theta > 0$ . Encontre uma estatística suficiente e minimal para  $\theta$ .

**Resposta**

Fazendo uma razão de densidades conjuntas para as amostras  $X_1, \dots, X_n$  e  $Y_1, \dots, Y_n$  ambas providas da mesma distribuição, temos que

$$\frac{f_{\mathbf{X}}(\mathbf{x})}{f_{\mathbf{X}}(\mathbf{y})} = \frac{\frac{1}{\theta^n} \prod_{i=1}^n \mathbb{I}_{(\theta, 2\theta)}(x_i)}{\frac{1}{\theta^n} \prod_{i=1}^n \mathbb{I}_{(\theta, 2\theta)}(y_i)} = \frac{\mathbb{I}_{(\theta, 2\theta)}(x_{(1)}) \mathbb{I}_{(x_{(1)}, 2\theta)}(x_n)}{\mathbb{I}_{(\theta, 2\theta)}(y_{(1)}) \mathbb{I}_{(y_{(1)}, 2\theta)}(y_n)}$$

com  $X_{(1)} = \min\{X_1, \dots, X_n\}$ ,  $X_{(n)} = \max\{X_1, \dots, X_n\}$ ,  $Y_{(1)} = \min\{Y_1, \dots, Y_n\}$  e  $Y_{(n)} = \max\{Y_1, \dots, Y_n\}$ . Para que a razão seja constante em relação à  $\theta$ , é preciso que  $x_{(1)} = y_{(1)}$  e  $x_{(n)} = y_{(n)}$ , pois assim os termos que dependem de  $\theta$  (os indicadores) se cancelariam. Então pelo Teorema,  $T(\mathbf{X}) = (X_{(1)}, X_{(n)})$  é um vetor de estatísticas suficiente e minimal para  $\theta$ .

- 8<sup>a</sup>) Demonstre que se  $X \sim f(x; \theta)$ , com  $f(\cdot)$  sendo uma densidade, ou seja,  $X$  é uma variável contínua, então  $Y = F(X; \theta)$  é ancilar para  $\theta$ , onde  $F(\cdot)$  é a distribuição acumulada de  $X$ .

**Resposta**

Vamos iniciar calculando a função de distribuição acumulada de  $Y$ , temos que

$$F_Y(y) = \mathbb{P}(Y \leq y) = \mathbb{P}(F(X) \leq y) = \mathbb{P}(X \leq F^{-1}(y)) = F(F^{-1}(y)) = y.$$

Dado que a função de distribuição acumulada de uma variável aleatória  $Z$  seguindo uma distribuição Uniforme no intervalo  $(0, 1)$  é da forma

$$F_Z(z) = P(Z \leq z) = z,$$

temos que  $Y = F(X) \sim U(0, 1)$  e, portanto, sua distribuição não depende de  $\theta$  implicando que  $Y$  é ancilar para  $\theta$ .

- 9<sup>a</sup>) Seja  $X_1, \dots, X_n$  uma amostra aleatória da distribuição uniforme  $U(0, \theta)$ . Mostre que a estatística  $T(X)$ :

$$T(X) = \frac{X_{(1)}}{X_{(n)}}, \quad X_{(n)} \neq 0,$$

é uma estatística ancilar para  $\theta$ . ( $X_{(1)} = \min\{X_1, \dots, X_n\}$  e  $X_{(n)} = \max\{X_1, \dots, X_n\}$ ).

**Resposta**

Dado que  $X_i \stackrel{iid}{\sim} U(0, \theta)$ , temos que  $X_i = \theta Y_i$ , com  $Y_i \stackrel{iid}{\sim} U(0, 1)$ , então  $X_{(n)} = \theta Y_{(n)}$  e  $X_{(1)} = \theta Y_{(1)}$ , assim

$$T(X) = \frac{X_{(1)}}{X_{(n)}} = \frac{\theta Y_{(1)}}{\theta Y_{(n)}} = \frac{Y_{(1)}}{Y_{(n)}}.$$

Portanto,  $T(X)$  não depende de  $\theta$ , pois é a razão entre duas variáveis seguindo  $U(0, 1)$ . Desse modo,  $T(X)$  é uma estatística ancilar para  $\theta$ .