

# Lista 4 - Inferência Estatística

Livro Robert Keener

17.  $X_1, X_2, \dots$  iid Poisson( $\theta$ )

$$W(\theta) = \log f_{\theta}(x) = -\theta + x \log \theta - \log x!$$

Assim  $I(\theta) = E[X^2/\theta^2] = 1/\theta$ . Com isso,

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, \theta),$$

$$\log \sqrt{n} \left( \frac{\hat{\theta}_n - \theta}{\sqrt{\theta}} \right) \xrightarrow{d} N(0, 1).$$

Usando  $I(\hat{\theta}_n) \approx I(\theta)$ , temos que

$$\sqrt{n}(\sqrt{\hat{\theta}_n} - \sqrt{\theta}) \xrightarrow{d} N(0, 1),$$

com  $\sigma_{\theta}(x) = \sqrt{x}$ .

21.  $f_{\theta}(x) = \frac{\theta e^{\theta x}}{2 \sinh \theta}$ ,  $x \in (-1, 1)$ .  $Y_i = \mathbb{1}\{X_i > 0\}$

$$\begin{aligned} a) \lambda(x|\theta) &= \log f_{\theta}(x_1, \dots, x_n) \\ &= n \log \theta + \theta \sum_{i=1}^n x_i - n \log 2 - n \log \sinh \theta \end{aligned}$$

Logo

$$\frac{d}{d\theta} \lambda(x|\theta) = \frac{n}{\theta} + \sum_{i=1}^n x_i - n \coth \theta = 0$$

$\Rightarrow \coth(\theta) - 1/\theta = \bar{x}$ . Além disso,

$$\frac{d^2}{d\theta^2} \lambda(x|\theta) = -\frac{n}{\theta^2} + n \operatorname{csch}^2 \theta < 0$$

deve ser satisfeito.

$$b) Y_i \sim \text{Bernoulli}(p(\theta)), \text{ em que, } p(\theta) = \int_0^1 \frac{\theta e^{\theta x}}{2 \sinh \theta} dx = \frac{e^{\theta} - 1}{e^{\theta} + e^{-\theta}}$$

O MLE para  $p(\theta)$  é  $\bar{Y}$ , portanto  $p^{-1}(\bar{Y})$  é o MLE para  $\theta$ .

## Livro Casella - Berger

7.1.

$$\hat{\theta} = \begin{cases} 1, & \text{se } x \in \{0, 1\} \\ 2, & \text{se } x = 2 \\ 3, & \text{se } x \in \{2, 3, 4\} \end{cases}$$

7.2.  $X_1, \dots, X_n \sim \text{Gamma}(\alpha, \beta)$

a)  $f_{\beta}(x_1, \dots, x_n) = \frac{\beta^{\alpha n}}{\Gamma(\alpha)^n} \prod_{i=1}^n x_i^{\alpha-1} e^{-\beta \sum_{i=1}^n x_i}$ ,

$$\text{logo } \frac{d}{d\beta} \log f_{\beta}(x_1, \dots, x_n) = \frac{\alpha n}{\beta} - \sum_{i=1}^n x_i = 0$$

$\Rightarrow \hat{\beta} = 1/n\alpha \sum_{i=1}^n x_i$  é MLE para  $\beta$ .

$$\frac{d^2}{d\beta^2} \log f_{\beta}(x_1, \dots, x_n) = -\frac{\alpha}{\beta^2} < 0 \Rightarrow \hat{\beta} \text{ minimizador global}$$

b)  $\frac{d}{d\alpha} \log f_{\alpha}(x_1, \dots, x_n) = n \log \beta - \psi(\alpha) + \sum_{i=1}^n \log x_i = 0$

$$\Rightarrow \psi(\alpha) = \sum_{i=1}^n \log x_i + n \log \beta$$

7.6. (a)  $f(x_1, \dots, x_n | \theta) = \theta^n (\prod_{i=1}^n x_i)^{-2} \mathbb{1}_{\{\min\{x_i\} \geq \theta\}}$   
Logo  $T(x) = (\prod_{i=1}^n x_i, x_{(1)})$  é estatística suficiente.

b) Note que a densidade cresce em  $\theta$ , mas é limitada por  $\min\{x_i\}$ . Logo o MLE é  $\hat{\theta} = x_{(1)}$ .

c)  $E_{\theta}[X_1] = \int_{\theta}^{\infty} \frac{\theta}{x} dx = \theta \ln(x) \Big|_{\theta}^{\infty} = \infty$ , logo o

método dos momentos não existe dessa forma. Mas

$$E_{\theta}[X_1^{1/2}] = \int_{\theta}^{\infty} \frac{\theta}{x^{3/2}} dx = -\theta x^{-1/2} \Big|_{\theta}^{\infty} = \sqrt{\theta}.$$

Logo  $\hat{\theta} = (\sum_{i=1}^n X_i^{1/2})^2$  é estimador por método de momentos (em um sentido)

7.11. a)  $f(x_1, \dots, x_n) = \theta^n (\prod_{i=1}^n x_i)^{\theta-1}$ . Assim

$$\frac{d}{d\theta} \log f(x_1, \dots, x_n) = \frac{n}{\theta} + \sum \log x_i = 0 \Rightarrow \hat{\theta} = \left( -\frac{1}{n} \sum_{i=1}^n \log x_i \right)^{-1}$$

$$\frac{d^2}{d\theta^2} \log f(x_1, \dots, x_n) = -\frac{n}{\theta^2} < 0 \Rightarrow \hat{\theta} \text{ é MLE para } \theta.$$

Defina  $Y_i = -\log X_i$ . Assim  $X_i = e^{-Y_i}$

$$\begin{aligned} f_{Y_i}(y) &= f_{X_i}(e^{-y}) e^{-y} \\ &= \theta (e^{-y})^{\theta-1} e^{-y} \\ &= \theta e^{-\theta y} \end{aligned}$$

$\Rightarrow Y_i \sim \text{Exponencial}(\theta)$ . Com isso

$$T = -\sum_{i=1}^n \log X_i \sim \text{Gamma}(n, \theta)$$

$$\Rightarrow \hat{\theta} = n/T = n(1/T) = n \text{ InvGamma}(n, \theta)$$

$$\Rightarrow \hat{\theta} \sim \text{InvGamma}(n, n\theta)$$

$$\text{Var}(\hat{\theta}) = \frac{n^2 \theta^2}{(n-1)^2 (n-2)} = \frac{n^2}{(n-1)^2} \frac{\theta^2}{(n-2)} \xrightarrow{n \rightarrow \infty} 0$$

b)  $X_i \sim \text{Beta}(\theta, 1)$ . Assim  $E[X_i] = \frac{\theta}{\theta+1}$ , logo

$$\bar{X}(\theta+1) = \theta \Rightarrow$$

$$\hat{\theta}_{MM} = \bar{X} / (1 - \bar{X})$$

7.12.  $X_1, \dots, X_n$  iid com  $P_\theta(X=x) = \theta^x (1-\theta)^{1-x}$

a)  $E[X] = \theta \Rightarrow \hat{\theta}_{MM} = \bar{X}$

$$\begin{aligned} \lambda(\theta|x) &= \log P_\theta(X_1=x_1, \dots, X_n=x_n) \\ &= \log \theta^{\sum_{i=1}^n x_i} + \log(1-\theta)^{\sum_{i=1}^n (1-x_i)} \end{aligned}$$

$$\frac{d}{d\theta} \lambda(\theta|x) = \frac{\sum_{i=1}^n x_i}{\theta} - \frac{\sum_{i=1}^n (1-x_i)}{1-\theta} = 0$$

$$\Rightarrow \frac{1}{\theta} - 1 = \frac{n - \sum x_i}{\sum x_i} \Rightarrow \theta = \bar{X}$$

$$\frac{d^2}{d\theta^2} \lambda(\theta|x) = -\frac{\sum x_i}{\theta^2} - \frac{\sum_{i=1}^n (1-x_i)}{(1-\theta)^2} < 0, \text{ logo}$$

$$\hat{\theta}_{MLE} = \begin{cases} \bar{x}, & \text{se } \bar{x} < 1/2 \\ 1/2, & \text{se } \bar{x} \geq 1/2 \end{cases} \rightarrow \text{Binomial}$$

b) e c) Fazer contas e verificar menor erro quadrático esperado.

7.19.  $Y_i = \beta x_i + \varepsilon_i$ ,  $\varepsilon_i \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2)$

$$\begin{aligned} (a) f_{\beta, \sigma^2}(y_1, \dots, y_n) &= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \beta x_i)^2\right\} \\ &\propto \exp\left\{-\frac{1}{2\sigma^2} \sum y_i^2 + \frac{\beta}{\sigma^2} \sum x_i y_i - \frac{\beta^2}{2\sigma^2} \sum x_i^2\right\} \end{aligned}$$

logo  $T(x) = (\sum_{i=1}^n y_i^2, \sum_{i=1}^n x_i y_i)$  é estatística suficiente.

$$(b) \frac{d}{d\beta} \log f_{\beta, \sigma^2}(y_1, \dots, y_n) = \frac{\sum x_i y_i}{\sigma^2} - \frac{\beta}{\sigma^2} \sum x_i^2 = 0$$

$$\Rightarrow \hat{\beta} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$$

Além disso,  $\frac{d^2}{d\beta^2} \log f_{\beta, \sigma^2}(y_1, \dots, y_n) = - \frac{\sum_{i=1}^n x_i^2}{\sigma^2} < 0$ ,

o que mostra que  $\hat{\beta}$  é MLE para  $\beta$ . Além disso,

$$E[\hat{\beta}] = \frac{\sum_{i=1}^n x_i E[Y_i]}{\sum_{i=1}^n x_i^2} = \beta.$$

$$(c) \frac{x_i}{\sum_{i=1}^n x_i^2} Y_i \sim \mathcal{N}\left(\frac{\beta x_i^2}{\sum_{i=1}^n x_i^2}, \frac{x_i^2}{(\sum_{i=1}^n x_i^2)^2} \sigma^2\right)$$
$$\Rightarrow \hat{\beta} \sim \mathcal{N}\left(\beta, \sigma^2 / \sum_{i=1}^n x_i^2\right).$$

7.37  $X_1, \dots, X_n \sim \text{Unif}(-\theta, \theta)$

É fácil ver que  $T(x) = \max\{|x_i|\}$  é estatística suficiente.

Vamos verificar que é completa. Temos que  $|x_i| \sim U(0, \theta)$ .

Assim

$$f_T(t) = \frac{d}{dt} \prod_{i=1}^n P(|X_i| \leq t)$$
$$= g^{-n} n t^{n-1}, \quad t \in [0, \theta).$$

Logo

$$E_\theta[g(T)] = \int_0^\theta g(t) n t^{n-1} dt = 0, \quad \forall \theta$$

$$\Rightarrow g(\theta) \theta^{n-1} = 0, \quad \forall \theta \Rightarrow g(\theta) = 0 \text{ e } T \text{ é completa.}$$

$$E[T] = \int_0^\theta \left(\frac{t}{\theta}\right)^n n dt = \int_0^1 n x^n \theta dx = \frac{n}{n+1} \theta$$

$$\Rightarrow S(x) = \frac{n+1}{n} \max\{|x_i|\} \text{ é UMVUE.}$$

7.38. Aplicar a relação

$$\frac{d}{d\theta} \log f(x|\theta) = a(\theta)(S(x) - g(\theta))$$

a estimadores que atingem o limite inferior de Cramér-Rao

Extras

$$1. \log f_{\theta}(x_1, \dots, x_n) = \log 2^{-n} \exp \left\{ - \sum_{i=1}^n |x_i - \theta| \right\}$$

$$= - \sum_{i=1}^n |x_i - \theta| - n \log 2$$

Fazendo  $\theta \rightarrow \pm \infty$ ,  $|x_i - \theta| \rightarrow +\infty$ , para  $i=1, \dots, n$ .

existe  $M \in \mathbb{R}$  tal que  $\theta \notin [-M, M] \Rightarrow \log f_{\theta}(x) < \log f_{\theta}(x)$ . Além do mais, como  $\log f_{\theta}(x)$  é contínua, sabemos que existe maximizador em  $[-M, M]$ . Ele é único, pois a função módulo. Além do mais, como  $-\log f_{\theta}(x)$  é convexa, todo mínimo local é global.

Se  $\theta \neq 0$ ,

$$\frac{d}{d\theta} \log f_{\theta}(x) = - \sum_{\{j: x_j > \theta\}} (-1) - \sum_{\{j: x_j < \theta\}} 1$$

$$= \# \{j: x_j > \theta\} - \# \{j: x_j < \theta\}$$

Logo  $\theta \log f_{\theta}(x) = \{ \# \{x_j > \theta\} - \# \{x_j < \theta\} \}$ . Assim, se  $\# \{x_j > \theta\} = \# \{x_j < \theta\} = n/2$ , temos que  $\theta$  é maximizador. Mas  $\theta \in [x_{(n/2)}, x_{(n/2+1)}]$  satisfaz essa condição. Logo o MLE não é único. Defina  $g'(\theta) = \cos \theta / \theta$ . Assim

$$h(\theta) = (\sin(\theta)/\theta, \cos(\theta)/\theta)$$

é invertível,  $h^{-1}(x, y) = \arctan(x/y)$ . Assim  $g(\hat{\theta}_{MLE})$  é MLE de  $g(\theta)$ . Veja que ele não é único e não é definido em  $\hat{\theta}_{MLE} = 0$ .