

# Monitoria 20/07/2022

**Exercício 1** Suponha que  $\{Y_i\}_{i \in \mathbb{N}}$  sejam variáveis aleatórias com distribuição Bernoulli com parâmetro  $p_i$ . Assuma que para cada  $i$ , é observado um vetor  $x_i \in \mathbb{R}^k$ , cujas coordenadas são chamadas de *covariáveis*. Além do mais, dado  $\theta$ , as variáveis  $Y_i$  são independentes com

$$\text{define-se como } \logit(p_i) := \log \left\{ \frac{p_i}{1-p_i} \right\} = \theta \cdot x_i, \quad \theta \in \mathbb{R}^k$$

Encontre uma estatística suficiente mínima para  $\theta$ .

Temos  $Y_i \sim \text{Bernoulli}(p_i)$ , com  $\logit(p_i) = \theta \cdot x_i$ .

Assim

$$\begin{aligned} \frac{p_i}{1-p_i} &= e^{\theta \cdot x_i} \Rightarrow p_i(1+e^{\theta \cdot x_i}) = e^{\theta \cdot x_i} \\ &\Rightarrow p_i = \frac{e^{\theta \cdot x_i}}{1+e^{\theta \cdot x_i}}. \end{aligned}$$

Com  $\theta$  fixo,  $\{Y_i\}_{i \in \mathbb{N}}$  são independentes. Assim,

$$\begin{aligned} f_Y(y_1, \dots, y_n | \theta) &= \prod_{i=1}^n f_{Y_i}(y_i | \theta) \\ &= \prod_{i=1}^n p_i^{y_i} (1-p_i)^{1-y_i} \quad \rightarrow \text{Densidade Bernoulli} \\ &= \prod_{i=1}^n \left( \frac{e^{\theta \cdot x_i}}{1+e^{\theta \cdot x_i}} \right)^{y_i} \left( \frac{1}{1+e^{\theta \cdot x_i}} \right)^{1-y_i} \\ &= \prod_{i=1}^n \frac{e^{y_i \theta \cdot x_i}}{1+e^{\theta \cdot x_i}} \\ &= \frac{e^{\sum y_i \theta \cdot x_i}}{\prod_{i=1}^n (1+e^{\theta \cdot x_i})} = \frac{e^{\theta \cdot \sum y_i x_i}}{\prod_{i=1}^n (1+e^{\theta \cdot x_i})} = \frac{e^{\theta \cdot T(y)}}{\prod_{i=1}^n (1+e^{\theta \cdot x_i})} \end{aligned}$$

com  $T(y) = \sum_{i=1}^n y_i x_i$ . Pelo Teorema de Fatorização, fazendo  $h(y) = 1$  e  $g(T(y) | \theta) = f_Y(y_1, \dots, y_n | \theta)$ ,  $T(y)$  é suficiente. Mais do que isso, verificamos que  $f_Y$  pertence à família exponencial.

• **Lehmann-Scheffé:** Se

$T(x) = T(y) \Leftrightarrow f(x|\theta) = f(y|\theta)h(x,y)$ ,  $\forall \theta$  e algum  $h$ ,  
então  $T$  é suficiente mínima.

Se  $T$  é suficiente, a ida é direta usando o Teorema da Fatorização, pois  $f(x|\theta) = h(x)g(T(x)|\theta)$   
 $= h(x)h(y)^{-1}h(y)g(T(y)|\theta)$   
 $= h(x)h(y)^{-1}f(y|\theta)$ .

Agora, suponha a volta:

$$\log h(y'|y'') = \log \frac{f(y'|\theta)}{f(y''|\theta)} = \theta \cdot (T(y') - T(y'')),$$

portanto  $T(y') = T(y'')$ . Com isso,  $T$  é suficiente mínima.

• **Bahadur:** Se  $T$  é suficiente completa limitada, então ela é suficiente mínima.

Como provar que  $T$  é completa?  $\forall \theta \in \Omega$

$$E_{\theta}[g(T)] = \sum_{T(y)=\sum y_i x_i} g(T(y)) \frac{e^{\theta \cdot T(y)}}{\prod_{i=1}^n 1 + e^{\theta \cdot x_i}} = 0$$

?  
 $\Rightarrow g(T) = 0$ .

Existe uma certa dificuldade em trabalhar com isso, mas como  $f_{\gamma}$  pertence à família exponencial e o espaço dos parâmetros  $\Omega = \mathbb{R}^k$  contém um conjunto aberto,  $T$  é suficiente completa e, portanto, suficiente mínima.

**Exercício 2** Sejam  $\{Z_i\}_{i \in \mathbb{N}}$  variáveis aleatórias com distribuição Bernoulli( $\theta$ ). Defina a quantidade aleatória  $X_1 = \min\{n : Z_n = 0\}$ .

- Escreva a densidade com respeito à medida de contagem da distribuição de  $X_1$ .
- Mostre que  $X_1$  é estatística suficiente para  $\theta$ .
- Encontre o estimador de máxima verossimilhança  $\hat{\theta}_1$  de  $\theta$  baseado em  $X_1$ .
- Mostre que o estimador  $\hat{\eta} = \hat{\theta}_1 / (1 - \hat{\theta}_1)$  é estimador não enviesado para a razão de chances  $\eta = \theta / (1 - \theta)$ .
- Usando o Teorema de Rao-Blackwell, é possível propor um estimador com variância menor?
- Calcule o limite inferior de Cramér-Rao do MSE para estimadores não enviesados.

$$\begin{aligned} a) \quad P(X_1 = k) &= P(Z_1 = 1, \dots, Z_{k-1} = 1, Z_k = 0) \\ &= \prod_{i=1}^{k-1} P(Z_i = 1) P(Z_k = 0) \\ &= \theta^{k-1} (1 - \theta) \quad \leadsto \text{Geométrica} \end{aligned}$$

Logo a densidade é  $f_X(x) = \theta^{x-1} (1 - \theta) \mathbb{1}_{\mathbb{N}}\{x\}$

b)  $f_{X_1}(x) = \theta^{x-1} (1 - \theta)$  e, portanto, pelo Teorema da Fatorização,  $X_1$  é suficiente.

c) A verossimilhança é

$$L(\theta | x) = \theta^{x-1} (1 - \theta)$$

$$\Rightarrow \log L(\theta | x) = (x-1) \log \theta + \log(1 - \theta)$$

Com isso

$$\frac{d}{d\theta} \log L(\theta | x) = \frac{x-1}{\theta} - \frac{1}{1-\theta} = 0$$

$$\Rightarrow \frac{x-1}{\theta} = \frac{1}{1-\theta} \Rightarrow \frac{1}{\theta} - 1 = \frac{1}{x-1} \Rightarrow \frac{1}{\theta} = \frac{x}{x-1}$$

$$\Rightarrow \theta = \frac{x-1}{x}. \text{ Além do mais,}$$

$$\frac{d^2}{d\theta^2} \log L(\theta | x) = -\frac{(x-1)}{\theta^2} - \frac{1}{(1-\theta)^2} < 0$$

$\Rightarrow \hat{\theta}_1 = (x-1)/x$  é MLE quando  $X_1 = x$ .

d)  $\hat{\eta} = \hat{\theta}_1 / (1 - \hat{\theta}_1)$ , então  $E_0[\hat{\eta}] = E\left[\frac{(x-1)/x}{1 - (x-1)/x}\right] = E[x] - 1 = \frac{1}{1-\theta} - 1 = \frac{\theta}{1-\theta}$

$\hat{\eta} = x-1 = \eta \Rightarrow \hat{\eta}$  é não viesado.

*média da Geométrica*

e) **Lehmann-Scheffé**: se  $T$  é completa, então todos os estimadores não enviesados que são funções de  $T$  (não de  $X$ ) são iguais quase certamente. Além disso, se o estimador é função de  $T$ , ele é UMVUE.

Como nossa distribuição é geométrica e o espaço de parâmetros  $\Omega = [0, 1]$  contém um aberto, então  $X_1$  é suficiente completa. Como  $\hat{\eta}$  é função de  $X_1$ , ele é UMVUE e Rao-Blackwell não consegue melhorar:

$$E[\hat{\eta} | X_1] \rightsquigarrow \text{Rao-Blackwell}$$

$\hookrightarrow$  estatística suficiente

f) Seja  $T$  estimador não enviesado para  $\eta$ . Assim,

$$\text{Var}_\eta(T) \geq [I_X(\eta)]^{-1}$$

em que  $I_X(\eta) = -E_\eta \left[ \frac{d^2}{d\eta^2} \log f(x|\eta) \right]$

$$= -E_\eta \left[ \frac{d}{d\eta} \left( \frac{d}{d\theta} \log f(x|\eta) \cdot \frac{d\theta}{d\eta} \right) \right]$$

$$= -E_\eta \left[ \frac{d^2}{d\theta^2} \log f(x|\eta) \left( \frac{d\theta}{d\eta} \right)^2 + \frac{d}{d\theta} \log f(x|\eta) \frac{d^2\theta}{d\eta^2} \right]$$

$\hookrightarrow$  meio chato de fazer

Sabemos que um estimador atinge o limite de Cramér-Rao se, e somente se,

$$\frac{d}{d\theta} \log f(x|\theta) = a(\theta) \phi(x) + b(\theta)$$

$$\begin{aligned} \frac{d}{d\eta} \log f(x_1|\eta) &= \frac{x_1-1}{\theta} - \frac{1}{1-\theta} = \frac{(1+\eta)(x_1-1)}{\eta} - (1+\eta) \\ &= \left(\frac{1+\eta}{\eta}\right) \hat{\eta} - (1+\eta) \end{aligned}$$

$\Rightarrow \hat{\eta}$  atinge o limite inferior de Cramér-Rao e  $\text{Var}(\hat{\eta}) = \text{Var}(x_1-1) = \text{Var}(x_1) = \theta/(1-\theta)^2$ .

**Exercício 3** Sejam  $X_1, \dots, X_n \stackrel{iid}{\sim} N(\theta, a\theta^2)$  com  $a > 0$  conhecido. Mostre que a estatística  $T(X) = (\bar{X}, S^2)$  é estatística suficiente mínima para  $\theta$ , mas a família de distribuições não é completa. Isso contradiz o fato de ela pertencer à família exponencial? Dica: qual a particularidade do espaço de parâmetros?

Para  $\sigma^2 = a\theta^2$ , sabemos que a estatística é suficiente mínima para  $(\theta, a\theta^2)$ . Note que, para  $x, y \in \mathbb{R}$

$$\log \frac{f(x|\theta, a\theta^2)}{f(y|\theta, a\theta^2)} = \frac{1}{a\theta} (\sum x_i - \sum y_i) - \frac{1}{2a\theta^2} (\sum x_i^2 - \sum_{i=1}^n y_i^2)$$

não depende de  $\theta$ , logo  $\sum x_i = \sum y_i$  e  $\sum x_i^2 = \sum y_i^2$ .  
Em particular  $(\bar{X}, S^2)$  é estatística suficiente mínima.

Observe que  $E[\bar{X}^2] = \text{Var}(\bar{X}) + E[\bar{X}]^2 = \frac{a\theta^2}{n} + \theta^2$  e

$E[S^2] = a\theta^2$ . Logo, fazendo  $c(\frac{a}{n} + 1) - a = 0$ , teremos

que  $E[c\bar{X}^2 - S^2] = 0$ , mesmo que  $c\bar{X}^2 - S^2 \neq 0$ .

Veja que o espaço  $\{(\theta, a\theta^2) : \theta \in \mathbb{R}\}$  não contém abertos.

**Exercício 4** Considere  $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Uniform}(\theta, \theta + 1)$ . Encontre uma estatística suficiente mínima e um estimador para  $\theta$ . Verifique:

- (a) Essa estatística é completa para a família de distribuições?
- (b) Esse estimador é não enviesado?
- (c) Esse estimador é consistente?

$$f_X(x_1, \dots, x_n | \theta) = \prod_{i=1}^n \mathbb{1}\{\theta \leq x_i \leq \theta + 1\}$$

$$= \mathbb{1}\{\min\{x_i\} \geq \theta \geq \max\{x_i\} - 1\}$$

Então  $T(x) = (\min x_i, \max x_i)$  é estatística suficiente.

Vamos usar Lehmann-Scheffman para provar que é mínima.

Seja  $f(x|\theta) = f(y|\theta)h(x,y)$ ,  $\forall \theta \in \mathbb{R}$ . Se  $\theta \in [\max x_i - 1, \min x_i]$ ,  $f(x|\theta) = 1$  e, portanto,  $f(y|\theta) \neq 0$ , isto é,  $f(y|\theta) = 1$  e  $h(x,y) = 1$ . Assim,  $\theta \in [\max y_i - 1, \min y_i]$ . Se  $\theta \notin [\max x_i - 1, \min x_i]$ , então  $f(x|\theta) = 0 \Rightarrow f(y|\theta) = 0$ . Com isso,  $\min x_i = \min y_i$  e  $\max x_i = \max y_i$ .  
 $\Rightarrow T$  é mínima.

MLE:  $T(x) \in [\min\{x_i\}, \max\{x_i\} - 1]$

Momentos:  $\theta + 1/2 = E[X] = \bar{X} \Rightarrow \hat{\theta} = \bar{X} - 1/2$ .

a) Não é completa. Defina  $R = \max\{x_i\} - \min\{x_i\}$ .

$$= (\max\{x_i\} - \theta) - (\min\{x_i\} - \theta)$$

$$= V_1 - V_2,$$

em que  $V_1 \sim \text{Unif}(0,1)$  e  $V_2 \sim \text{Unif}(0,1)$ . Assim,  $R$  é estatística ancilar. Pelo Teorema de Basu, se  $T$  fosse completa, então  $R$  e  $T$  seriam independentes, um absurdo. Com isso,  $T$  não é completa.

b) Sim.  $E[\bar{X} - 1/2] = E[X_1] - 1/2 = 0$ .

c) Sim,  $\theta = \bar{X} - 1/2 \xrightarrow{P} E[X] - 1/2$  pela Lei dos Grandes Números e  $E[X] = \theta + 1/2$ .

d) As condições de regularidade de Fisher não são satisfeitas.  $C = \{x : f(x|\theta) > 0\} = [\theta, \theta + 1]$ , que depende de  $\theta$ !

**Exercício 5** (Monte Carlo Swindles) Seja  $X = (X_1, \dots, X_n)$  uma amostra aleatória com distribuição  $N(\mu, \sigma^2)$  e  $M_n$  a mediana amostral. Defina  $v_n = \text{Var}_{\mu, \sigma^2}(M_n)$ . Nesse exercício, vamos estudar a estimação de  $v_n$  através do método de Monte Carlo.

- (a) Considere  $N$  amostras aleatórias de tamanho  $n$ , denotadas por  $(X_1^i, \dots, X_n^i)$  e seja  $M_n^i$  a mediana da  $i$ -ésima amostra,  $i = 1, \dots, N$ . Calcule a variância amostral  $S_N^2$  de  $\{M_n^1, \dots, M_n^N\}$ . Mostre que a sequência  $\{S_N^2\}_{N \in \mathbb{N}}$  é consistente para  $v_n$ .
- (b) Mostre que  $\bar{X}_n$  é estatística suficiente completa e  $V = (X_1 - \bar{X}_n, \dots, X_n - \bar{X}_n)$  é estatística ancilar para  $\mu$ . Conclua que  $\bar{X}_n$  e  $M_n - \bar{X}_n$  são independentes.
- (c) Calcule  $\text{Var}(\bar{X}_n)$  e mostre a relação entre  $v_n$  e  $\text{Var}(M_n - \bar{X}_n)$ .
- (d) Usando a relação acima e a ideia destacada em (a), discuta uma outra sequência de estimadores para  $v_n$ .
- (e) Encontre aproximações para a variância do estimador de (a) e de (d) usando que a normalidade assintótica. Conclua que para  $n$  suficientemente grande, o método em (d) tem variância menor e, portanto, maior precisão. Essa abordagem é chamada de *Monte Carlo Swindles*.

a)  $v_n = E_{\mu, \sigma^2} [(M_n - E[M_n])^2]$

$$S_N^2 = \frac{1}{N-1} \sum_{i=1}^N (M_n^i - \bar{M}_n)^2$$

$$= \frac{N}{N-1} \left( \frac{1}{N} \sum_{i=1}^N (M_n^i)^2 - \bar{M}_n^2 \right)$$

$$:= \frac{N}{N-1} \left( \overline{M_n^2} - \bar{M}_n^2 \right).$$

Pela lei dos grandes números,  $\overline{M_n^2} \xrightarrow{P} E[M_n^2]$  e  $\bar{M}_n \xrightarrow{P} E[M_n]$ . Como  $x \mapsto x^2$  é contínua,  $\overline{M_n^2} \xrightarrow{P} E[M_n^2]$ . Com isso

$$\overline{M_n^2} - \overline{M_n}^2 \xrightarrow{P} E[M_n^2] - E[M_n]^2 = \text{Var}(M_n) = v_n,$$

$$\begin{aligned} x_n \xrightarrow{P} X, y_n \xrightarrow{P} Y &\Rightarrow x_n + y_n \xrightarrow{P} X + Y \\ P(|x_n + y_n - (x + y)| > \varepsilon) &\leq P(|x_n - x| + |y_n - y| > \varepsilon) \\ &\leq P(|x_n - x| > \varepsilon/2 \text{ ou } |y_n - y| > \varepsilon/2) \\ &\leq P(|x_n - x| > \varepsilon/2) + P(|y_n - y| > \varepsilon/2) \rightarrow 0 \end{aligned}$$

$$a_n \rightarrow a, X_n \xrightarrow{P} X, a \neq 0$$

$$\begin{aligned} P(|a_n X_n - a X| > \varepsilon) &\leq P(|a_n X_n - a_n X| + |a_n X - a X| > \varepsilon) \\ &\leq P(|a_n| |X_n - X| > \varepsilon/2) + P(|a_n - a| |X| > \varepsilon) \end{aligned}$$

Tome  $n$  grande para  $|a_n - a| < 1$

$$\begin{aligned} &\leq P(|a| |X_n - X| > \varepsilon/4) + P(|a_n - a| |X_n - X| > \varepsilon/4) + P(|a_n - a| |X| > \varepsilon) \\ &\leq P(|X_n - X| > \varepsilon/4|a|) + P(|X_n - X| > \varepsilon/4) + P(|a_n - a| |X| > \varepsilon) \\ &\quad \rightarrow 0 \qquad \qquad \qquad \rightarrow 0 \qquad \qquad \qquad \rightarrow 0 \end{aligned}$$

desde que  $P(|X| = +\infty) = 0$

$$\text{Como } \frac{N}{N-1} \xrightarrow{N \rightarrow \infty} 1, \quad S_N^2 \xrightarrow{P} v_n.$$

b) Com  $\sigma^2$  fixo, como  $\mathbb{R}$  contém um aberto, e a distribuição Normal pertence à família exponencial,  $\bar{X}_n$  é suficiente completa. Note que

$$(x_1 - \bar{x}, \dots, x_n - \bar{x}) = \left( I - \frac{1}{n} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix} \right) (x_1, \dots, x_n)$$

tem distribuição normal, com média 0 e variância

$$\begin{aligned} &\left( I - \frac{1}{n} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix} \right) \sigma^2 \mathbb{I} \left( I - \frac{1}{n} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix} \right) \\ &= \sigma^2 \left( I - \frac{1}{n} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix} \right), \end{aligned}$$

que não depende de  $\mu$ . Logo é estatística auxiliar.

Pelo Teorema de Basu,  $\bar{X}$  e  $(x_1 - \bar{x}, \dots, x_n - \bar{x})$  são independentes. Além do mais  $M_n = f(x_1, \dots, x_n) \Rightarrow M_n - \bar{X}$  independe de  $\bar{X}$ .

$$c) \text{Var}(\bar{X}) = \sigma^2/n$$

$$v_n = \text{Var}(M_n) = \text{Var}(M_n - \bar{X} + \bar{X}) = \text{Var}(M_n - \bar{X}) + \text{Var}(\bar{X})$$

↳ independência

d) Para cada amostra,  $\{X_1^i, \dots, X_n^i\}$ ,  $i=1, \dots, N$ , calcule a média e mediana amostral  $M_n^i$  e  $\bar{X}^i$ , respectivamente.

Por fim, calcule

$$\tilde{S}_N^2 = \frac{1}{N-1} \sum_{i=1}^N (M_n^i - \bar{X}^i - \frac{1}{N} \sum_{i=1}^N (M_n^i - \bar{X}^i))^2 + \frac{\sigma^2}{n}$$

$$\xrightarrow{p} \text{Var}(M_n - \bar{X}) + \sigma^2/n = v_n$$

e) Temos que (aplicando o método Delta),  $M_n^i$  é aproximadamente normal para  $n$  suficientemente grande, portanto,  $M_n^i - \bar{X}^i$  também é aproximadamente normal,  $\forall i \in \{1, \dots, N\}$ .

Com isso

$$\frac{(N-1) S_N^2}{\text{Var}(M)} \quad \text{e} \quad \frac{(N-1) (\tilde{S}_N^2 - \sigma^2/n)}{\text{Var}(M - \bar{X})}$$

tem distribuição aproximada chi-quadrado com  $N-1$  graus. Em particular, ambos tem variância aproximada  $2(N-1)$ , para  $n$  grande.

$$\text{Var} \left( \frac{(N-1) S_N^2}{\text{Var}(M)} \right) \approx 2(N-1) \Rightarrow \text{Var} S_N^2 \approx \frac{2 \text{Var}^2 M_n}{N-1} \quad n \rightarrow \infty$$

$$\text{Var} \left( \frac{(N-1) (\tilde{S}_N^2 - \frac{\sigma^2}{n})}{\text{Var}(M - \bar{X})} \right) \approx 2(N-1) \Rightarrow \text{Var}(\tilde{S}_N^2) \approx \frac{2 \text{Var}^2(M_n - \bar{X}_n)}{N-1}$$

Note que

$$\text{Var}(M_n - \bar{X}) = \text{Var}(M_n) - \text{Cov}(M_n, \bar{X}) + \text{Var}(\bar{X})$$

<  $\text{Var}(M_n)$ , para  $n$  suf. grande.

correlação alta

$\sigma^2/n$  pequeno

**Exercício 6** Considere uma amostra aleatória  $X_1, \dots, X_n \sim N(\theta, \sigma^2)$ .

- (a) Proponha um estimador baseado no método de momentos para  $(\theta, \sigma)$ .  
 (b) Calcule o estimador de máxima verossimilhança para  $(\theta, \sigma)$ .  
 (c) Seja  $\hat{\sigma}^2$  o MLE para  $\sigma^2$  e  $S^2$  a variância amostral. Calcule seus vieses.  
 (d) Mostre que  $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$  e  $\hat{s} = \sqrt{S^2}$  são enviesados.

a)  $\theta = E[X] = \frac{1}{n} \sum_{i=1}^n X_i$   
 $\sigma^2 + \theta^2 = E[X^2] = \frac{1}{n} \sum_{i=1}^n X_i^2$   
 Assim  $\sigma^2 = \frac{1}{n} (\sum X_i^2 - (\sum X_i)^2) \Rightarrow \sigma = \sqrt{\frac{1}{n} (\sum X_i^2 - (\sum X_i)^2)}$   
 é solução do sistema. Portanto  
 $\hat{\theta} = \bar{X}_n$  e  $\hat{\sigma} = \left[ \frac{1}{n} (\sum X_i^2 - (\sum X_i)^2) \right]^{1/2}$   
 é estimador do método de momentos.

b)  $\lambda(\theta|x) = \log f(x|\theta) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2 - n \log \sqrt{2\pi} \sigma$

Assim  $\frac{d}{d\theta} \lambda(\theta|x) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \theta) = 0 \Rightarrow \hat{\theta} = \bar{X}$ .

$\frac{d}{d\sigma} \lambda(\theta|x) = \frac{1}{\sigma^3} \sum_{i=1}^n (x_i - \theta)^2 - \frac{n}{\sigma} = 0 \Rightarrow \hat{\sigma} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2}$

Teorema de Cochran

c) Sabemos que  $n \frac{\hat{\sigma}^2}{\sigma^2} \sim \chi_{n-1}^2$ , portanto

$$E[\hat{\sigma}^2] = E\left[\frac{\sigma^2}{n} \frac{n}{\sigma^2} \cdot \hat{\sigma}^2\right] = \frac{\sigma^2}{n} (n-1) = \frac{n-1}{n} \sigma^2$$

$$E[S^2] = E\left[\frac{\sigma^2}{(n-1)} \frac{(n-1)}{\sigma^2} S^2\right] = \frac{\sigma^2}{n-1} \cdot (n-1) = \sigma^2$$

d) Suponha que não sejam viesados:

$$\sigma^2 = E[\hat{\sigma}]^2 = E[\hat{\sigma}^2] - \text{Var}(\hat{\sigma}) = \frac{n-1}{n} \sigma^2 - \text{Var}(\hat{\sigma})$$

$$\Rightarrow \text{Var}(\hat{\sigma}) = -\sigma^2/n < 0, \text{ um absurdo.}$$

$$\sigma^2 = E[\hat{s}]^2 = E[\hat{s}^2] - \text{Var}(\hat{s}) = \sigma^2 - \text{Var}(\hat{s})$$

$$\Rightarrow \text{Var}(\hat{s}) = 0 \Rightarrow \hat{s} \stackrel{q.c.}{=} \text{const.}, \text{ um absurdo.}$$

**Exercício 7** Expresse a família das distribuições Beta na família exponencial. Encontre o parâmetro natural, o espaço de parâmetros natural e estatísticas suficientes. Encontre a média e a variância das estatísticas suficientes. (Dica: Veja sobre as funções digamma e trigamma.)

$$f_{\alpha, \beta}(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} \mathbb{1}(x \in (0, 1))$$

$$= \underbrace{\mathbb{1}_{(0,1)}(x)}_{h(x)} \underbrace{\frac{1}{B(\alpha, \beta)}}_{c(\alpha, \beta)} \exp \left\{ \alpha \log(x) + \beta \log(1-x) \right\}$$

Parâmetro natural:  $(\alpha, \beta)$

Espaço:  $\int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx < +\infty \Leftrightarrow \alpha, \beta > 0$

$$= \mathbb{R}_+^2$$

Estatística suficiente:  $T(x_1, \dots, x_n) = (\sum \log(x_i), \sum \log(1-x_i))$

$$E[\log(x)] = \frac{d}{d\alpha} \log B(\alpha, \beta) = \psi(\alpha) - \psi(\alpha + \beta)$$

$$E[\log(1-x)] = \frac{d}{d\beta} \log B(\alpha, \beta) = \psi(\beta) - \psi(\alpha + \beta)$$

$$\text{Var}(\log(x)) = \frac{d^2}{d\alpha^2} \log B(\alpha, \beta) = \psi'(\alpha) - \psi'(\alpha + \beta)$$

$$\text{Var}(\log(1-x)) = \frac{d^2}{d\beta^2} \log B(\alpha, \beta) = \psi'(\beta) - \psi'(\alpha + \beta)$$

8. a)  $f(x|k, p) = \binom{k}{x} p^x (1-p)^{k-x}$

$$L(k, p|\vec{x}) = \prod_{i=1}^n \binom{k}{x_i} p^{x_i} (1-p)^{k-x_i}$$

$$\ell(k, p) = \sum_{i=1}^n \ln \binom{k}{x_i} + \ln p \sum_{i=1}^n x_i + (nk - \sum_{i=1}^n x_i) \ln(1-p)$$

$$\frac{\partial \ell(\hat{k}, \hat{p})}{\partial p} = \frac{\sum_{i=1}^n x_i}{\hat{p}} - \frac{n\hat{k} - \sum_{i=1}^n x_i}{1-\hat{p}} = 0 \Rightarrow \hat{p} = \frac{\sum_{i=1}^n x_i}{n\hat{k}}$$

Note que

$$\frac{L(k, \hat{p})}{L(k-1, \hat{p})} = \prod_{i=1}^n \frac{k}{k-x_i} (1-\hat{p}) = \frac{[k(1-\hat{p})]^n}{\prod_{i=1}^n (k-x_i)}$$

Quando  $[k(1-\hat{p})]^n \geq \prod_{i=1}^n (k-x_i)$ ,  $L$  cresce em  $k$ .  
Como  $L(\hat{k}, \hat{p})$  maximiza a verossimilhança,

$$[\hat{k}(1-\hat{p})]^n \geq \prod_{i=1}^n (\hat{k}-x_i) \text{ e } [(\hat{k}+1)(1-\hat{p})]^n < \prod_{i=1}^n (\hat{k}+1-x_i)$$

b) e c) Basta verificar que  $\hat{k}$  satisfaz as relações acima.

**Exercício 9** Suponha que  $X$  e  $Y$  sejam variáveis aleatórias independentes cujas distribuições parametrizadas por  $\theta$  têm densidade  $f_X(x|\theta)$  e  $f_Y(y|\theta)$ , respectivamente. Suponha que  $\theta \in \Omega \subset \mathbb{R}$ . Mostre que  $I_{X,Y}(\theta) = I_X(\theta) + I_Y(\theta)$ .

Se  $X$  e  $Y$  são independentes,  $f_{X,Y}(x,y|\theta) = f_X(x|\theta) f_Y(y|\theta)$ . Logo, valem as condições de regularidade de FI.

$$I_{X,Y}(\theta) = \mathbb{E} \left[ \left( \frac{d}{d\theta} \log f_{X,Y}(X,Y|\theta) \right)^2 \right]$$

$$= E \left[ \left( \frac{d}{d\theta} \log f_X(X|\theta) + \frac{d}{d\theta} \log f_Y(Y|\theta) \right)^2 \right]$$

independência  $\rightarrow$

$$= I_X(\theta) + I_Y(\theta) + 2 E \left[ \frac{d}{d\theta} \log f_X(X|\theta) \frac{d}{d\theta} \log f_Y(Y|\theta) \right]$$

$$= I_X(\theta) + I_Y(\theta) + 2 E \left[ \frac{d}{d\theta} \log f_X(X|\theta) \right] E \left[ \frac{d}{d\theta} \log f_Y(Y|\theta) \right]$$

$$= I_X(\theta) + I_Y(\theta) + 2 \int \frac{d}{d\theta} f_X(x|\theta) dx \int \frac{d}{d\theta} f_Y(y|\theta) dy$$

$$= I_X(\theta) + I_Y(\theta) + 2 \left( \frac{d}{d\theta} 1 \right) \left( \frac{d}{d\theta} 1 \right)$$

$$= I_X(\theta) + I_Y(\theta).$$

**Exercício 10** Seja  $X \sim \text{Poi}(\theta)$  e defina  $g(\theta) = \exp\{-3\theta\} \Rightarrow \theta = -\frac{1}{3} \log \eta$

(a) Encontre o limite inferior de Cramér-Rao para estimadores não viesados de  $g(\theta)$ .

(b) Se  $\phi(X) = (-2)^X$ , encontre  $\text{Var}_\theta(\phi(X))$ .

(c) Encontre o limite inferior de Cramér-Rao e de Chapman-Robbins para a variância de estimadores não viesados de  $\theta$ .

a) Denote  $\eta = g(\theta)$ . Vamos calcular  $I_X(\eta)$ :

$$I(\eta) = - E_\eta \left[ \frac{d^2}{d\eta^2} \log f(x|\eta) \right]$$

$$= - E_\eta \left[ \frac{d^2}{d\eta^2} (x \log \theta - \theta - \log x!) \right]$$

$$= - E_\eta \left[ \frac{d}{d\eta} \left( \frac{x}{\theta} \frac{d\theta}{d\eta} - \frac{d\theta}{d\eta} \right) \right]$$

$$= E_\eta \left[ \frac{x}{\theta^2} \left( \frac{d\theta}{d\eta} \right)^2 - \frac{x}{\theta} \frac{d^2\theta}{d\eta^2} + \frac{d^2\theta}{d\eta^2} \right]$$

$$= \left( \frac{(d\theta/d\eta)^2}{\theta^2} - \frac{d^2\theta/d\eta^2}{\theta} \right) E_\eta[x] + \frac{d^2\theta}{d\eta^2}$$

$$= \frac{1}{\theta} \left( \frac{d\theta}{d\eta} \right)^2 = - \frac{\log \eta}{\eta^2}$$

Assim, o limite inferior de Cramér-Rao é  $-\frac{\eta^2}{\log \eta}$ .

$$b) E[\phi(x)] = \sum_{k=0}^{\infty} (-2)^k \frac{\theta^k}{k!} e^{-\theta} = e^{-\theta} \sum_{k=0}^{\infty} \frac{(-2\theta)^k}{k!} = e^{-3\theta}$$

$$E[\phi^2(x)] = \sum_{k=0}^{\infty} (-2)^{2k} \frac{\theta^k}{k!} e^{-\theta} = e^{-\theta} \sum_{k=0}^{\infty} \frac{(4\theta)^k}{k!} = e^{3\theta}$$

Assim  $\text{Var}_\theta(\phi(x)) = e^{3\theta} - e^{-6\theta}$ .

$$c) I_x(\theta) = -E\left[\frac{d^2}{d\theta^2}(x \log \theta - \theta - \log x!)\right]$$

$$= -E\left[\frac{d}{d\theta}\left(\frac{x}{\theta} - 1\right)\right]$$

$$= -E\left[-\frac{x}{\theta^2}\right] = \frac{1}{\theta}$$

Cramér-Rao:  $\text{Var}_\theta(T(x)) \geq \theta$

Chapman - Robbins:

$$\text{Var}_\theta\left(\frac{f(x|\theta')}{f(x|\theta)}\right) = \text{Var}_\theta\left(\left(\frac{\theta'}{\theta}\right)^x e^{-(\theta'-\theta)}\right) = e^{-2(\theta'-\theta)} \text{Var}_\theta\left(\left(\frac{\theta'}{\theta}\right)^x\right)$$

$$E_\theta\left[\left(\frac{\theta'}{\theta}\right)^x\right] = \sum_{k=0}^{\infty} \left(\frac{\theta'}{\theta}\right)^k \frac{\theta^k}{k!} e^{-\theta} = e^{-\theta+\theta'\theta}$$

$$= e^{-2(\theta'-\theta)} \left( e^{-\theta+\theta'^2/\theta} - e^{2(\theta'-\theta)} \right)$$

$$= e^{\frac{(\theta-\theta')^2}{\theta}} - 1$$

$$E_\theta\left[\left(\frac{\theta'}{\theta}\right)^{2x}\right] = \sum_{k=0}^{\infty} \left(\frac{\theta'}{\theta}\right)^{2k} \frac{\theta^k}{k!} e^{-\theta} = e^{-\theta+\theta'^2/\theta}$$

Veja que  $e^{\frac{x^2}{\theta}} \geq \frac{x^2}{\theta} + 1$   
 $\Rightarrow \theta \geq \frac{x^2}{e^{\frac{x^2}{\theta}} - 1}$

Assim  $\sup_{\theta' \neq \theta} \left\{ \frac{(\theta - \theta')^2}{e^{\frac{(\theta - \theta')^2}{\theta}} - 1} \right\} = \sup_{x \neq 0} \left\{ \frac{x^2}{e^{\frac{x^2}{\theta}} - 1} \right\} = \theta$

**Exercício 11** Suponha que  $n$  flechas são lançadas em um alvo circular de raio  $r$  e que a  $i$ -ésima flecha passa no ponto  $(X_i, Y_i)$ . Assuma que os pares  $(X_i, Y_i)$  são independentes com distribuição  $N(0, \theta I_2)$ .

- (a) Defina  $R_i = \sqrt{X_i^2 + Y_i^2}$ . Encontre a distribuição de  $R_i^2/\theta$  para uma flecha arbitrária.  
 (b) Calcule a probabilidade da  $i$ -ésima aresta atingir o alvo.  
 (c) Encontre o MLE de  $\theta$  e a distribuição assintótica do estimador.

a)  $X_i \sim N(0, \theta)$  e  $Y_i \sim N(0, \theta)$ . Como  $\text{Cor}(X_i, Y_i) = 0$ , vale que  $X_i$  e  $Y_i$  são independentes, pois são normalmente distribuídas. Assim  $X_i^2/\theta \sim \chi_1^2$  e  $Y_i^2/\theta \sim \chi_1^2$ , e portanto,  

$$\frac{R_i^2}{\theta} \sim \chi_2^2.$$

Assim  $R_i^2/\theta \sim \text{Exp}(1/2)$ , em particular.

b)  $P(R_i^2 \leq r^2) = P\left(\frac{R_i^2}{\theta} \leq \frac{r^2}{\theta}\right)$   
 $= 1 - e^{-\frac{1}{2} \frac{r^2}{\theta}}$

c)  $f(\mathbf{x}, \mathbf{y} | \theta) = \prod_{i=1}^n \frac{1}{2\pi\theta} \exp\left\{-\frac{1}{2\theta}(x_i^2 + y_i^2)\right\}$   
 $= \frac{1}{(2\pi)^n} \theta^{-n} \exp\left\{-\frac{1}{2\theta} \sum_{i=1}^n R_i^2\right\}$

$\Rightarrow \lambda(\theta | \mathbf{x}, \mathbf{y}) = -n \log \theta - \frac{1}{2\theta} \sum_{i=1}^n R_i^2 - n \log 2\pi$

$\Rightarrow \frac{d}{d\theta} \lambda(\theta | \mathbf{x}, \mathbf{y}) = -\frac{n}{\theta} + \frac{1}{2\theta^2} \sum_{i=1}^n R_i^2 = 0 \Rightarrow \theta = \frac{1}{2n} \sum_{i=1}^n R_i^2$

$\frac{d^2}{d\theta^2} \lambda(\theta | \mathbf{x}, \mathbf{y}) \Big|_{\theta = \frac{\sum R_i^2}{2n}} = \frac{n}{\theta^2} - \frac{1}{\theta^3} \sum_{i=1}^n R_i^2$

$= \frac{1}{\theta^2} \left( n - \frac{\sum R_i^2}{\frac{1}{2n} \sum R_i^2} \right) = -\frac{n}{\theta^2} < 0,$

logo  $\hat{\theta} = \frac{1}{2n} \sum_{i=1}^n R_i^2$  é MLE para  $\theta$ .

$$\begin{aligned}
I_X(\theta) &= -\mathbb{E} \left[ \frac{n}{\theta^2} - \frac{1}{\theta^3} \sum_{i=1}^n R_i^2 \right] \\
&= -\frac{n}{\theta^2} + \frac{1}{\theta^2} \sum \mathbb{E} \left[ \frac{R_i^2}{\theta} \right] \\
&= -\frac{n}{\theta^2} + \frac{n}{\theta^2} \mathbb{E} \left[ \frac{R_i^2}{\theta} \right] \\
&= \frac{n}{\theta^2}
\end{aligned}$$

Logo  $\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{D} \mathcal{N}(0, \theta^2)$ , isto é,  
 $\hat{\theta} \approx \mathcal{N}(\theta, \theta^2/n)$