

1. Questão 1

(a) Temos que

$$\begin{aligned} f(\mathbf{x}; \theta) &= \theta^n (1 - \theta)^{n\bar{x} - n} \mathbb{1}_A(\mathbf{x}) = \exp \left\{ n\bar{x} \ln(1 - \theta) + n \ln \left( \frac{\theta}{1 - \theta} \right) \right\} \mathbb{1}_A(\mathbf{x}) \\ &= \exp \{c(\theta)t(\mathbf{x}) + d(\theta)\} \mathbb{1}_A(\mathbf{x}) \\ &= \exp \{\eta t(\mathbf{x}) + d_0(\eta)\} \mathbb{1}_A(\mathbf{x}) \end{aligned}$$

em que  $c(\theta) = \ln(1 - \theta)$ ,  $t(\mathbf{x}) = \sum_{i=1}^n x_i$ ,  $A = \mathcal{N}^n$ ,  $d(\theta) = n \ln \left( \frac{\theta}{1 - \theta} \right)$ ,  $\eta = \ln(1 - \theta) \rightarrow \theta = 1 - e^\eta$ ,  $d_0(\eta) = n \ln \left( \frac{1 - e^\eta}{e^\eta} \right) = n (\ln(1 - e^\eta) - \eta)$ ,  $\Theta_\eta = \mathbb{R}^-$  que contem segmentos de reta, assim,  $T$  é suficiente, minimal e completa.

(b) Temos que  $\mathcal{E} \left( \frac{T}{n} \right) = \frac{1}{n} \sum_1^n \mathcal{E}(X_i) = \frac{1}{\theta}$ . Por LS,  $\frac{T}{n}$  é o ENVVUM de  $\theta$ .

(c) Temos que

$$\begin{aligned} L(\theta) &\propto \theta^n (1 - \theta)^{n\bar{x} - n} \rightarrow n \ln \theta + n(\bar{x} - 1) \ln(1 - \theta) \\ S(\theta) &= \frac{n}{\theta} - \frac{n(\bar{x} - 1)}{1 - \theta}, H(\theta) = -\frac{n}{\theta^2} - \frac{n(\bar{x} - 1)}{(1 - \theta)^2} \\ I(\theta) &= \frac{n}{\theta^2} + \frac{n}{\theta(1 - \theta)} = n \frac{1 - \theta + \theta}{\theta^2(1 - \theta)} = \frac{n}{\theta^2(1 - \theta)} \end{aligned}$$

$$S(\tilde{\theta}) = 0 \rightarrow n - n\tilde{\theta} = \tilde{\theta}n\bar{x} - n\theta \rightarrow \tilde{\theta} = \frac{1}{\bar{x}}$$

Como  $H(\tilde{\theta}) < 0$ , então  $\hat{\theta} = \frac{1}{\bar{X}}$  é o EMV de  $\theta$ .

(d) Supondo as condições de regularidade satisfeitas, temos que  $\sqrt{n} \left( \hat{\theta} - \theta \right) \rightarrow N(0, \theta^2(1 - \theta))$

(e) Pelo resultado do item anterior, temos que  $IC_A(\theta; \gamma) = \left[ \hat{\theta} - z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\theta}^2(1-\hat{\theta})}{n}}; \hat{\theta} + z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\theta}^2(1-\hat{\theta})}{n}} \right]$ , em que  $P(Z \leq z_{\frac{1+\gamma}{2}}) = \frac{1+\gamma}{2}$ .

2. Questão 2) Defina  $(y_i = |x_i|, y_1 = \min\{|x_1|, \dots, |x_n|\}, y_n = \max\{|x_1|, \dots, |x_n|\})$ :

(a) Temos que

$$f_{\mathbf{X}}(\mathbf{x}; \theta) = \frac{1}{(2\theta)^n} \prod_{i=1}^n \mathbb{1}_{(0,\theta)}(|x_i|) = \frac{1}{(2\theta)^n} \mathbb{1}_{(0,\theta)}(y_n) \mathbb{1}_{(0,y_n)}(y_1)$$

Por outro lado, temos que:

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{x}^*; \theta)} = \frac{\mathbb{1}_{(0,\theta)}(y_n) \mathbb{1}_{(0,y_n)}(y_1)}{\mathbb{1}_{(0,\theta)}(y_n^*) \mathbb{1}_{(0,y_n^*)}(y_1^*)} = Q(\mathbf{x}, \mathbf{x}^*) \leftrightarrow y_n = y_n^* \quad (1)$$

assim,  $Y_n$  é uma estatística suficiente e minimal. Além disso, temos que  $f_{Y_n}(y; \theta) = \frac{ny^{n-1}}{\theta^n} \mathbb{1}_{(0,\theta)}(y)$ . Assim, vem que:

$$\begin{aligned} \mathcal{E}(g(Y_n)) &= 0 \rightarrow \int_0^\theta g(y) \frac{ny^{n-1}}{\theta^n} dy = 0 \\ &= \int_0^\theta g(y) y^{n-1} dy = 0 \rightarrow g(\theta) \theta^{n-1} = 0 \\ &\rightarrow g(\theta) = 0, \forall \theta \in \Theta \end{aligned} \quad (2)$$

Portanto, como  $\mathcal{X} \subset \Theta$ , então  $g(y) = 0, \forall y \in \mathcal{X}$ . Logo,  $Y_n$  também é uma estatística completa.

(b) Temos que  $\mathcal{E}(X) = 0$ , portanto, não nos serve para calcular o EMM de  $\theta$ . Por outro lado, temos que  $\mathcal{E}(X^2) = \frac{\theta^2}{12}$  e, logo:

$$\frac{\hat{\theta}^2}{12} = \frac{1}{n} \sum_{i=1}^n X_i^2 \rightarrow \hat{\theta} = \pm 2 \sqrt{\frac{3}{n} \sum_{i=1}^n X_i^2} \quad (3)$$

Logo, como  $\theta \in (0, \infty)$  então  $\hat{\theta} = 2 \sqrt{\frac{3}{n} \sum_{i=1}^n X_i^2}$  é o EMM de  $\theta$ .

(c) Temos que

$$\begin{aligned}\mathcal{E}(\hat{\theta}^*) &= \frac{2}{n} \sum_{i=1}^n \mathcal{E}(|X_i|) = \frac{2}{n} \frac{\theta n}{2} = \theta \\ \mathcal{V}(\hat{\theta}^*) &= \frac{4}{n} \frac{\theta^2}{12} = \frac{\theta^2}{3n} \\ \mathcal{B}(\hat{\theta}^*) &= 0; \mathcal{E}\mathcal{Q}\mathcal{M}(\hat{\theta}^*) = \mathcal{V}(\hat{\theta}^*) + \mathcal{B}^2(\hat{\theta}^*) = \frac{\theta^2}{3n}\end{aligned}$$

(d) Do item a), temos que:

$$L(\theta) \propto \frac{1}{(2\theta)^n} \mathbb{1}_{(y_n, \infty)}(\theta)$$

Que é uma função decrescente (em  $\theta$ ), pois  $L'(\theta) = \frac{-n}{2\theta^{n+1}}$ . Assim,  $\hat{\theta} = Y_n$  é o EMV de  $\theta$ . Por outro lado, temos que:

$$\begin{aligned}\mathcal{E}(Y_n^k) &= \frac{n}{\theta^n} \int_0^\infty y^{n+k-1} dy = \frac{n\theta^{n+k}}{(n+k)\theta^n}, \forall n+k > 1 \\ &= \frac{n\theta^k}{(n+k)}\end{aligned}$$

Portanto,  $EM(Y_n) = \frac{n\theta}{n+1}$ ,  $\mathcal{B}(Y_n) = \frac{-\theta}{n+1}$  e  $\mathcal{E}(Y_n) = \frac{n\theta^2}{(n+2)}$ . Logo,

$$\begin{aligned}\mathcal{V}(Y_n) &= \frac{n\theta^2}{(n+2)} - \frac{n^2\theta^2}{(n+1)^2} = \frac{\theta^2}{(n+2)(n+1)^2} (n(n^2+2n+1) - n^3 - 2n^2) \\ &= \frac{n\theta^2}{(n+2)(n+1)^2}\end{aligned}$$

e

$$\begin{aligned}\mathcal{E}\mathcal{Q}\mathcal{M}(Y_n) &= \frac{n\theta^2}{(n+2)(n+1)^2} + \frac{\theta^2}{(n+1)^2} \\ &= \frac{\theta^2}{(n+2)(n+1)^2} (n+n+2) = \frac{2\theta^2}{(n+2)(n+1)}\end{aligned}$$

(e) Como pelo menos um dos estimadores é viciado, comparemos seus EQM's, assim:

$$\frac{\mathcal{EQM}(\hat{\theta}^*)}{\mathcal{EQM}(Y_n)} = \frac{n^2 + 5n + 2}{6n} = g(n) > 1$$

Como  $g(n)$  é uma razão de polinômios em que grau daquele do que numerador,  $g(n) > 1, \forall n$ .

(f) Pelo item a) temos que  $Y_n$  é uma estatística suficiente completa e minimal. Por outro lado, pelo item d), temos que  $\mathcal{E}(Y_n) = \frac{n}{n+1}\theta$ . Logo, pelo Teorema de LS, temos que  $Y_n = \frac{n+1}{n}Y_n$  é o ENVVUM de  $\theta$ .

3. Questão 3)

(a) Temos que:

$$\begin{aligned}
 f_{\mathbf{X}}(\mathbf{x}; \theta) &= \left[ \prod_{i=1}^m \binom{m}{x_i} \right] \theta^{n\bar{x}} (1-\theta)^{n(1-\bar{x})} \prod_{i=1}^n \mathbb{1}_{\{0,1,2,\dots,m\}}(x_i) \\
 &= \exp \left\{ n\bar{x} \ln \left( \frac{\theta}{1-\theta} \right) + n \ln(1-\theta) \right\} h(\mathbf{x}) \mathbb{1}_A(\mathbf{x}) \\
 &= \exp \{ t(\mathbf{x})x(\theta) + d(\theta) \} h(\mathbf{x}) \mathbb{1}_A(\mathbf{x}) \\
 &= \exp \{ t(\mathbf{x})\eta + d_0(\eta) \} h(\mathbf{x}) \mathbb{1}_A(\mathbf{x})
 \end{aligned}$$

em que  $t(\mathbf{x}) = \sum_{i=1}^n x_i$ ,  $c(\theta) = \ln \left( \frac{\theta}{1-\theta} \right)$ ,  $h(\mathbf{x}) = \prod_{i=1}^m \binom{m}{x_i} \theta^{n\bar{x}}$ ,  $A = \{0, 1, 2, \dots, m\}^n$ ,  $\eta = \ln \left( \frac{\theta}{1-\theta} \right)$ ,  $\theta = \frac{1}{1+e^{-\eta}}$ ,  $d(\theta) = n \ln(1-\theta)$ ,  $d_0(\eta) = -n \ln(1-e^{-\eta})$ . Assim, como  $\Theta_\eta = \mathbb{R}$  contem algum segmento de reta, então  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  é uma estatística suficiente, completa e minimal.

(b) Defina  $T = T(\mathbf{X}) = \frac{1}{nm} \sum_{i=1}^n X_i$ . Temos que  $\mathcal{E}(T) = \theta$ . Logo, pelo item a) e pelo TLS, temos que  $T$  é o ENVUUM para  $\theta$ . Além disso, temos que

$$\begin{aligned}
 l(\theta) &= c + n\bar{x} \ln \theta + n(1-\bar{x}) \ln(1-\theta) \\
 S(\theta) &= \frac{n\bar{x}}{\theta} - \frac{n(1-\bar{x})}{1-\theta}; H(\theta) = -\frac{n\bar{x}}{\theta^2} - \frac{n(1-\bar{x})}{(1-\theta)^2} \\
 I(\theta) &= \frac{n}{\theta} + \frac{n}{(1-\theta)} = \frac{n}{\theta(1-\theta)}
 \end{aligned}$$

Assim,  $LICR(\theta) = \frac{\theta(1-\theta)}{n}$ . Além disso,  $VM(T) = \frac{1}{n^2 m^2} nm\theta(1-\theta) = \frac{\theta(1-\theta)}{n} = LICR(\theta)$ .

c) Sob as condições de regularidade, temos que  $\sqrt{n}(\hat{\theta} - \theta) \rightarrow N(0, \theta(1-\theta))$ . Logo,

$$IC_A(\theta, \gamma) = \left[ \hat{\theta} - z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}}; \hat{\theta} + z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}} \right]$$

d) Seja  $T^*(\mathbf{X}) = \mathbb{1}_{\{X_1=0 \cup X_1=1\}}$ . Então,  $\mathcal{E}(T^*) = P(X_1 = 0 \cup X_1 = 1) = (1-\theta)^m + m\theta(1-\theta)^{m-1} = (1-\theta)^{m-1}(m+1-\theta)$ . Por outro lado, temos que  $S = \sum_{i=1}^n X_i$  é uma estatística suficiente e completa (item a)). Dessa, forma, temos que  $T = \mathcal{E}(T^*|S)$  é o ENVVUM de  $\theta$ . Além disso:

$$\begin{aligned}
T = P(X_1 = 0 \cup X_1 = 1|S) &= \frac{1}{P(S = s)} [P(X_1 = 0, S = s) + P(X_1 = 1, S = s)] \\
&= \frac{1}{P(S = s)} \left[ P(X_1 = 0) P\left(\sum_{i=2}^n X_i = s\right) \right. \\
&\quad \left. + P(X_1 = 1) P\left(\sum_{i=2}^n X_i = s - 1\right) \right] \\
&= \frac{1}{\binom{mn}{s} \theta^s (1 - \theta)^{mn-s}} \left( (1 - \theta)^m \binom{m(n-1)}{s} \theta^s (1 - \theta)^{m(n-1)-s} \right. \\
&\quad \left. + m\theta (1 - \theta)^{m-1} \binom{m(n-1)}{s-1} \theta^{s-1} (1 - \theta)^{m(n-1)-s+1} \right) \\
&= \frac{1}{\binom{mn}{s}} \left( \binom{m(n-1)}{s} + m \binom{m(n-1)}{s-1} \right)
\end{aligned}$$

4. Questão 4

(a) Temos que

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}; \boldsymbol{\theta}) &= \sigma^{-n} \exp \left\{ -\frac{n\bar{x}}{\sigma} + n\frac{\mu}{\sigma} \right\} \mathbb{1}_{(\mu, \infty)}(y_1) \mathbb{1}_{(y_1, \infty)}(y_n) \\ &= g(\mathbf{t}; \boldsymbol{\theta}) h(\mathbf{x}) \end{aligned}$$

em que  $\mathbf{t} = (\sum_{i=1}^n x_i, y_1)'$ ,  $g(\mathbf{t}; \boldsymbol{\theta}) = \sigma^{-n} \exp \left\{ -\frac{n\bar{x}}{\sigma} + n\frac{\mu}{\sigma} \right\} \mathbb{1}_{(\mu, \infty)}(y_1)$ ,  $h(\mathbf{x}) = \mathbb{1}_{(y_1, \infty)}(y_n)$   
Assim, pelo CF temos que  $\mathbf{T} = (\sum_{i=1}^n X_i, Y_1)'$

(b) Temos que  $\mathcal{E}(X) = \sigma + \mu$ ,  $\mathcal{V}(X) = \sigma^2$ ,  $\mathcal{E}(X^2) = \sigma^2 + (\sigma + \mu)^2$ . Assim

$$\begin{aligned} \hat{\sigma} + \hat{\mu} &= \bar{X} \\ \hat{\sigma}^2 + (\hat{\sigma} + \hat{\mu})^2 &= \bar{X}_2 \rightarrow \hat{\sigma} = \sqrt{\bar{X}_2 - \bar{X}^2} \end{aligned}$$

Logo,  $\hat{\mu} = \bar{X} - \sqrt{\bar{X}_2 - \bar{X}^2}$  e  $\hat{\sigma} = \sqrt{\bar{X}_2 - \bar{X}^2}$ , são os EMM's de  $\boldsymbol{\theta}$ .

(c) Temos que:

$$L(\mu) \propto \exp \left\{ \frac{n\mu}{\sigma} \right\} \mathbb{1}_{(0, y_1]}(\mu)$$

Como a função acima é crescente em  $\mu$  ( $\exp \left\{ \frac{n\mu}{\sigma} \right\} \frac{n}{\sigma}$ ), temos que  $\hat{\mu} = Y_1$ . Além disso, temos que:

$$Y_1 = Y_1^* + \mu$$

em que  $Y_1^* = \min\{Y_1, \dots, Y_n\}$

$$f_{Y_1^*}(y; \sigma) = \frac{n}{\sigma} \exp \left\{ -\frac{ny}{\sigma} \right\} \sim \exp(\sigma/n)$$

Logo,  $\mathcal{E}(Y_1) = \frac{\sigma}{n} + \mu$ ,  $\mathcal{V}(Y_1) = \frac{\sigma^2}{n^2}$ .

(d) Temos que

$$\begin{aligned}
l(\mu) &= -n \ln \sigma - \frac{n}{\sigma} (\bar{x} - \mu); S(\mu) = -\frac{n}{\sigma} + \frac{n}{\sigma^2} (\bar{x} - \mu) \\
H(\mu) &= \frac{n}{\sigma^2} - \frac{2n}{\sigma^3} (\bar{x} - \mu); I(\mu) = \frac{n}{\sigma^2} - \frac{2n}{\sigma^3} (\bar{x} - \mu) = -\frac{n}{\sigma^2}
\end{aligned}$$

Temos que  $S(\tilde{\mu}) = 0 \rightarrow \tilde{\sigma} = \bar{x} - \mu$ . Como  $H(\tilde{\mu}) < 0$ ,  $\hat{\mu} = \bar{X} - \mu$ . Por outro lado, temos que

$$\mathcal{E}(\hat{\mu}) = \sigma; \mathcal{V}(\hat{\mu}) = \frac{\sigma^2}{n}$$

(e) Temos que:

$$S_X(x; \sigma) = \exp \left\{ -\frac{x - \mu}{\sigma} \right\}$$

Logo,  $Q = \frac{2n(\bar{X} - \mu)}{\sigma} \sim \chi_{2n}^2$ , logo

$$P(q_1 \leq Q \leq q_2) = \gamma \leftrightarrow P\left(\frac{2n(\bar{X} - \mu)}{q_2} \leq \sigma \leq \frac{2n(\bar{X} - \mu)}{q_1}\right) = \gamma$$

$$\text{Assim, } IC(\sigma; \gamma) = \left[ \frac{2n(\bar{X} - \mu)}{q_2}; \frac{2n(\bar{X} - \mu)}{q_1} \right]$$