

Redução de dados

Prof. Caio Azevedo

Introdução

- De posse de uma amostra aleatória $\mathbf{X} = (X_1, \dots, X_n)'$ de $X \sim F_x(\cdot, \boldsymbol{\theta})$, $\boldsymbol{\theta} \in \Theta \subseteq \mathcal{R}^k$, desejamos construir funções de \mathbf{X} que preservem (ou contenham) o máximo de informação possível (se possível tudo) sobre $\boldsymbol{\theta}$.
- Deseja-se que tais funções conduzam a conclusões confiáveis (acuradas) sobre o parâmetro de interesse $\boldsymbol{\theta}$.
- Def: Uma função $T = t(\mathbf{X}) : \mathcal{X} \rightarrow \mathcal{R}$ é dita ser uma estatística. Ela não pode depender do parâmetro $\boldsymbol{\theta}$.
- A informação que a estatística T contém sobre $\boldsymbol{\theta}$ é induzida, essencialmente, pela verossimilhança (que depende do(s) procedimento(s) amostral(is)/experimental(is) utilizado(s)) associada à \mathbf{X} (aa) e a eventuais suposições adicionais.

Introdução

- Def: A verossimilhança associada à uma aa $\mathbf{X} = (X_1, \dots, X_n)'$ de $X \sim F_X(\cdot; \theta)$ (com respectiva fdp $f_X(\cdot; \theta)$) é dada por

$$L(\theta; \mathbf{x}) = L(\theta) = \prod_{i=1}^n f_X(x_i; \theta)$$

- Exemplo: Seja $X_i \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$, $\theta \in (0, 1)$ e defina $T = \sum_{i=1}^n X_i$. Considere $n = 3$, assim

$$\mathcal{X} = \{(0, 0, 0), (1, 0, 0), (0, 1, 0), (0, 0, 1), (1, 1, 0), (1, 0, 1), (0, 1, 1), (1, 1, 1)\}$$

Cont. do Exemplo


- Defina o seguinte conjunto $A_t = \{\mathbf{x} \in \mathcal{X} : t(\mathbf{x}) = t\}$.
- Observe que os conjuntos A_t 's ($A_t \subset \mathcal{X}$) formam uma partição de \mathcal{X} pois

$$A_t \cap A_{t'} = \emptyset, \forall t \neq t'; \cup_{t \in B} A_t = \mathcal{X}$$

em que $B = \{t \in \mathcal{R}, t(\mathbf{x}) = t\}, \forall \mathbf{x} \in \mathcal{X}$.

- Note que: $A_0 = \{(0, 0, 0)\}$, $A_1 = \{(1, 0, 0), (0, 1, 0), (0, 0, 1)\}$, $A_2 = \{(1, 1, 0), (1, 0, 1), (0, 1, 1)\}$ e $A_3 = \{(1, 1, 1)\}$.

Representação gráfica (Estatística)



Outros exemplos

- μ (parâmetro de localização):
 - $T_1 = t_1(\mathbf{X}) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$.
 - $T_2 = t_2(\mathbf{X}) = \text{med}(\mathbf{X})$, med: mediana.
 - $T_3 = Y_1 + \frac{Y_n}{2}$, em que Y_i é a i -ésima estatística de ordem da amostra \mathbf{X} , ou seja $Y_1 \leq Y_2 \leq \dots \leq Y_n \equiv$ aos valores ordenados de forma crescente, de \mathbf{X} .

Outros exemplos

- σ^2 (parâmetro de escala).
 - $T_1 = t_1(\mathbf{X}) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$.
 - $T_2 = t_2(\mathbf{X}) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$.
 - $T_3 = \frac{1}{n} \sum_{i=1}^n |X_i - \bar{X}|$.
- Obs: Se $\mathbf{x}, \mathbf{y} \in \mathcal{X}$ são tais que $t(\mathbf{x}) = t(\mathbf{y})$, então as inferências a respeito de θ , considerando \mathbf{x} ou \mathbf{y} , serão equivalentes entre si.

Suficiência

- Em geral, os conceitos vistos nesta parte, aplicam-se, com as devidas adaptações, ao caso em que T é um vetor, ou seja $\mathbf{T} = (T_1, \dots, T_r)'$, $T_j = t_j(\mathbf{X}), j = 1, 2, \dots, r$, bem como quando θ for um vetor $(\boldsymbol{\theta})$.
- Def: Uma estatística T é dita ser suficiente para $\theta \in \Theta \subseteq \mathcal{R}$ se a distribuição conjunta da amostra condicionada em T , não depende de θ , ou seja se

$$f_{\mathbf{X}}(\mathbf{x}|t; \theta) = f_{\mathbf{X}}(\mathbf{x}|t), \forall \mathbf{x} \in \mathcal{X}.$$

Suficiência

- Em outras palavras, dado o conhecimento de T , a amostra não contém nenhuma informação relevante (adicional) a respeito de θ (embora ela ainda possa conter informação relevante, e geralmente contém, a respeito do modelo estatístico $F_{\mathbf{X}}(\cdot, \theta)$).
- No caso discreto, a definição anterior traduz-se em

$$P_{\theta}(\mathbf{X} = \mathbf{x} | T = t) = P(\mathbf{X} = \mathbf{x} | T = t), \forall \mathbf{x} \in \mathcal{X}.$$

Suficiência

- Exemplo: Seja $X_i \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$, $\theta \in (0, 1)$. Defina $T = \sum_{i=1}^n X_i$. Nesse caso, (notando que $T \sim \text{binomial}(n, \theta)$), se $P(T(\mathbf{X}) = t(\mathbf{x})) \neq 0$, temos que:

$$\begin{aligned} P_\theta(\mathbf{X} = \mathbf{x} | T = t) &= \frac{P_\theta(\mathbf{X} = \mathbf{x}, T = t)}{P_\theta(T = t)} \\ &= \frac{\theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i} \prod_{i=1}^n \mathbb{1}_{\{0,1,2,\dots,n\}}(x_i)}{\binom{n}{t} \theta^t (1 - \theta)^{n-t} \mathbb{1}_{\{0,1,2,\dots,n\}}(t)} \\ &= \frac{1}{\binom{n}{t}} \prod_{i=1}^n \mathbb{1}_{\{0,1,2,\dots,n\}}(x_i). \end{aligned}$$

Por outro lado, se $P(T(\mathbf{X}) = t(\mathbf{x})) \equiv 0$, teremos

$P_\theta(\mathbf{X} = \mathbf{x} | T = t) = \frac{P_\theta(\mathbf{X}=\mathbf{x}, T=t)}{P_\theta(T=t)} = 0$. Logo, como a distribuição de $\mathbf{X} | T = t$ não depende de θ , T é uma estatística suficiente para esse parâmetro.

Suficiência

- Exemplo: Seja $X_i \stackrel{iid}{\sim} \text{Poisson}(\theta)$, $\theta \in (0, \infty)$. Defina $T = \sum_{i=1}^n X_i$. Nesse caso, (notando que $T \sim \text{Poisson}(n\theta)$), se $P(T(\mathbf{X}) = t(\mathbf{x})) \neq 0$, temos que:

$$\begin{aligned} P_{\theta}(\mathbf{X} = \mathbf{x} | T = t) &= \frac{P_{\theta}(\mathbf{X} = \mathbf{x}, T = t)}{P_{\theta}(T = t)} \\ &= \frac{\frac{e^{-n\theta} \theta^{\sum_{i=1}^n x_i}}{\prod_{i=1}^n x_i!} \prod_{i=1}^n \mathbb{1}_{\{0,1,2,\dots\}}(x_i)}{\frac{e^{-n\theta} (n\theta)^t}{t!} \mathbb{1}_{\{0,1,2,\dots\}}(t)} \\ &= \frac{t!}{n^t \prod_{i=1}^n x_i!} \prod_{i=1}^n \mathbb{1}_{\{0,1,2,\dots\}}(x_i) \end{aligned}$$

Por outro lado, se $P(T(\mathbf{X}) = t(\mathbf{x})) \equiv 0$, teremos

$P_{\theta}(\mathbf{X} = \mathbf{x} | T = t) = \frac{P_{\theta}(\mathbf{X}=\mathbf{x}, T=t)}{P_{\theta}(T=t)} = 0$. Logo, como a distribuição de $\mathbf{X} | T = t$ não depende de θ , T é uma estatística suficiente para esse parâmetro.

Suficiência

- O procedimento anterior é válido quando T é uma vad. Se T for uma vac, temos que
 $P_{\theta}(T = t) = 0, \forall t \in \mathcal{T}$ (espaço associado a distribuição T), $\forall \theta \in \Theta$.
- Teorema: Seja $q_T(t; \theta)$ a fdp de $T = t(\mathbf{X})$. Então T é suficiente para θ , se e somente se $\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{q_T(t; \theta)}$ não depender de θ , sendo T discreta ou contínua.
- Prova para o caso discreto (para o caso contínuo, veja Testing Statistical Hypothesis (2005)).

Suficiência (dem. do teorema)

- Temos que:

$$\begin{aligned} P_{\theta}(\mathbf{X} = \mathbf{x} | T = t) &= \frac{P_{\theta}(\mathbf{X} = \mathbf{x}, T = t)}{P_{\theta}(T = t)} \\ &\stackrel{*}{=} \frac{P_{\theta}(\mathbf{X} = \mathbf{x})}{P_{\theta}(T = t)} = \frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{q_T(t; \theta)}, \end{aligned}$$

(*) pois $\{\omega \in \mathcal{X} : \mathbf{X}(\omega) = \mathbf{x}\} \subset \{\omega \in \mathcal{X} : T(\omega) = t\}$.

Suficiência

- Exemplo: Seja $X_i \stackrel{iid}{\sim} U[0, \theta], \theta \in \mathcal{R}^+$. Defina $Y_n = \max\{\mathbf{X}\}$.
- Primeiramente note que:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}; \theta) &= \frac{1}{\theta^n} \prod_{i=1}^n \mathbb{1}_{[0, \theta]}(x_i) = \frac{1}{\theta^n} \mathbb{1}_{[0, \theta]}(y_n) \mathbb{1}_{[0, y_n]}(y_1) \\ &= \frac{1}{\theta^n} \mathbb{1}_{[y_1, \theta]}(y_n) \mathbb{1}_{[0, \theta]}(y_1), \end{aligned}$$

em que $y_1 = \min\{\mathbf{x}\}$. Com efeito, $0 \leq x_i \leq \theta, \forall i \leftrightarrow 0 \leq y_1 < y_n \leq \theta$.

Suficiência: cont. exemplo

- Podemos ainda provar que:

$$q_{Y_n}(y_n; \theta) = \frac{n}{\theta^n} y_n^{n-1} \mathbb{1}_{(0, \theta)}(y_n) \text{ (exercício)}$$

- Portanto, temos que

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{q_{Y_n}(y_n; \theta)} = \frac{\frac{1}{\theta^n} \mathbb{1}_{[0, \theta]}(y_n) \mathbb{1}_{[0, y_n]}(y_1)}{\frac{n}{\theta^n} y_n^{n-1} \mathbb{1}_{(0, \theta)}(y_n)} = \frac{1}{n y_n^{n-1}} \mathbb{1}_{[0, y_n]}(y_1)$$

Logo Y_n é uma estatística suficiente para θ .

Teorema da Fatoração (Neyman)

- Seja $f_{\mathbf{X}}(\cdot, \theta)$ a fdp de $\mathbf{X} = (X_1, \dots, X_n)'$, $\theta \in \Theta \in \mathcal{R}$. A estatística $T(\equiv t(\mathbf{X}))$ é suficiente para θ se, e somente se, \exists duas funções, digamos, g, h , $g : \mathcal{R}^n \rightarrow \mathcal{R}^+$, $h : \mathcal{R}^n \rightarrow \mathcal{R}^+$, tais que

$$f_{\mathbf{X}}(\mathbf{x}; \theta) = g(t(\mathbf{x}); \theta)h(\mathbf{x})$$

em que h não depende de θ e g depende de \mathbf{x} apenas a através de t .

Teorema da Fatoração (Neyman)

- Prova (caso discreto): (\rightarrow) Defina:

$$h(\mathbf{x}) = P(\mathbf{X} = \mathbf{x} | T = t); g(t; \theta) = P_{\theta}(T = t)$$

Por outro lado, temos que:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}; \theta) &= P_{\theta}(\mathbf{X} = \mathbf{x}) = P_{\theta}(\mathbf{X} = \mathbf{x}, T(\mathbf{X}) = t(\mathbf{x})) \\ &= P_{\theta}(\mathbf{X} = \mathbf{x} | T = t) P_{\theta}(T = t) \\ &\stackrel{(*)}{=} P(\mathbf{X} = \mathbf{x} | T = t) P_{\theta}(T = t) \\ &= h(\mathbf{x}) g(t; \theta) \end{aligned}$$

Teorema da Fatoração (Neyman)

- Prova: (\leftarrow). Temos que:

$$P_{\theta}(\mathbf{X} = \mathbf{x}) = g(t(\mathbf{x}); \theta)h(\mathbf{x}).$$

- Defina $q_T(t; \theta)$ a fdp de T e $A_t = \{\mathbf{x} \in \mathcal{X}; t(\mathbf{x}) = t\}$.
- Precisamos mostrar que: $\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{q_T(t; \theta)}$ não depende de θ , para que T seja suficiente para θ .

Teorema da Fatoração (Neyman)

- Por outro lado, temos que:

$$\begin{aligned}\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{q_T(t; \theta)} &= \frac{g(t(\mathbf{x}); \theta)h(\mathbf{x})}{P_{\theta}(T = t)} = \frac{g(t(\mathbf{x}); \theta)h(\mathbf{x})}{\sum_{\mathbf{y} \in A_t} P_{\theta}(\mathbf{X} = \mathbf{y})} \\ &= \frac{g(t(\mathbf{x}); \theta)h(\mathbf{x})}{\sum_{\mathbf{y} \in A_t} g(t(\mathbf{y}); \theta)h(\mathbf{y})} \stackrel{*}{=} \frac{g(t; \theta)}{g(t; \theta)} \frac{h(\mathbf{x})}{\sum_{\mathbf{y} \in A_t} h(\mathbf{y})} \\ &= \frac{h(\mathbf{x})}{\sum_{\mathbf{y} \in A_t} h(\mathbf{y})}\end{aligned}$$

que não depende de θ ((* note que, neste caso, $t(\mathbf{y}) \equiv t$). Como o resultado vale $\forall A_t \subseteq \mathcal{X}$, então T é suficiente para θ .

Exemplo 1

- Seja X_1, \dots, X_n uma aa de $X \sim U(0, \theta), \theta > 0$. Temos que

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \theta) &= \frac{1}{\theta^n} \prod_{i=1}^n \mathbb{1}_{(0, \theta)}(x_i) = \frac{1}{\theta^n} \mathbb{1}_{(0, \theta)}(y_n) \mathbb{1}_{(0, y_n)}(y_1) \\ &= g(t(\mathbf{x}); \theta)\end{aligned}$$

em que $g(t(\mathbf{x}); \theta) = \frac{1}{\theta^n} \mathbb{1}_{(0, \theta)}(y_n)$ e $h(\mathbf{x}) = \mathbb{1}_{(0, y_n)}(y_1)$ e Y_i é a i -ésima estatística de ordem.

- Logo pelo critério da fatoração, temos que Y_n é uma estatística suficiente para θ .

Exemplo 2

- Seja X_1, \dots, X_n uma aa de $X \sim N(\mu, \sigma^2)$, $\mu \in \mathcal{R}$, $\sigma^2 \in \mathcal{R}^+$. Temos que

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \boldsymbol{\theta}) &= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\} \prod_{i=1}^n \mathbb{1}_{\mathcal{R}}(x_i) \\&= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n [(x_i - \bar{x}) + (\bar{x} - \mu)]^2 \right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}) \\&= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \left[\sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2 \right] \right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}) \\&= g(\mathbf{t}; \boldsymbol{\theta}) h(\mathbf{x})\end{aligned}$$

Exemplo 2 (cont.)

- Pois $\sum_{i=1}^n (x_i - \bar{x}) = 0$, $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$. Além disso,

$$g(t(\mathbf{x}); \theta) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \left[\sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2 \right] \right\}$$

e

$$h(\mathbf{x}) = \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}).$$

- Logo pelo critério da fatoração, temos que $\mathbf{T} = (\bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2)'$ é uma estatística suficiente para θ .

■ Resultados

- a) Se $T_1 = g(T_2)$ e T_1 é uma estatística suficiente para θ , então T_2 também o é.
- b) Se a função $g(\cdot)$, do item a) for 1 a 1, então T_1 é suficiente para θ , se e somente se T_2 o for.

■ Prova(s): exercício. Sugestão: critério da fatoração.

- Obs: Toda informação, a respeito de θ , contida em T_1 , também está contida em T_2 .
- Obs: As informações, a respeito de θ , contidas em T_1 e T_2 , são equivalentes entre si.


Exemplo 3

- Seja $X_i \stackrel{iid}{\sim} U(\theta, \theta + 1), \theta > 0$.
 - Nesse caso, pode-se provar que $(Y_1, Y_n)'$ é uma estatística suficiente para θ .
 - Seja $g : \mathcal{R}^2 \rightarrow \mathcal{R}, g(x, y) = y$, nesse caso $g(\mathbf{T}) = g(Y_1, Y_n) = Y_n$, não é uma estatística suficiente para θ (exercício).
 - OBS: Nem toda função de uma estatística suficiente é uma estatística suficiente.
 - OBS: Dada uma estatística suficiente, podemos encontrar várias outras estatísticas suficientes, como função desta.
 - OBS: Sempre existem estatísticas suficientes, p.e., $\mathbf{T}_1 = (X_1, \dots, X_n)'$ e $\mathbf{T}_2 = (Y_1, \dots, Y_n)$ (estatísticas de ordem). Prova: exercício. Estas são chamadas de estatísticas suficientes triviais.

Minimalidade

- Pergunta: É possível encontrar uma estatística suficiente que consiga uma redução máxima dos dados, sem perda de informação sobre θ ?
- Sejam P_1 e P_2 duas partições de \mathcal{X} , $P_1 = \{A_\alpha : \alpha \in I\}$ e $P_2 = \{B_\gamma : \gamma \in I'\}$, em que I e I' são índices convenientes.
- Assuma que $\forall B_\gamma \in P_2, \exists$ elementos de P_1 , $B_\gamma = \cup_{\alpha' \in J} A_{\alpha'}, J \subset I$.
Ou seja (próxima figura):

Representação gráfica (partição)



Minimalidade

- Seja $T_2 = g(T_1)$, T_1 e T_2 , estatísticas.
- Sejam $\mathbf{x}, \mathbf{y} \in A_1$. Então, se $T_1(\mathbf{x}) = T_1(\mathbf{y}) \rightarrow T_2(\mathbf{x}) = T_2(\mathbf{y})$.
- Sejam agora, $\mathbf{x} \in A_1$ e $\mathbf{y} \in A_4$, então:
 $T_2(\mathbf{x}) = T_2(\mathbf{y}) \not\rightarrow T_1(\mathbf{x}) = T_1(\mathbf{y})$.
- Def: Uma estatística, digamos T , é suficiente e minimal para θ , se T , além de ser suficiente, for função de toda outra estatística suficiente, digamos T' . Em outras palavras:
 - T é suficiente.
 - Se T' é suficiente $\exists g, T = g(T')$.

Exemplo & Teorema

- Seja $X_i \stackrel{iid}{\sim} N(\mu, \sigma^2)$, σ^2 conhecido. Podemos provar que $T = \bar{X}$ é suficiente e minimal para θ .
- Seja, também, $T' = (\bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2)$. Podemos provar que T' é suficiente para θ , contudo, $T = g(T')$.
- Teorema: Seja $f_{\mathbf{X}}(\cdot; \theta)$ a fdp de $\mathbf{X} = (X_1, \dots, X_n)'$ e \exists **uma estatística T , a razão $\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{y}; \theta)}$ não depende de θ , se e somente se, $t(\mathbf{x}) = t(\mathbf{y})$, $\forall \theta \in \Theta$ e $\forall \mathbf{x}, \mathbf{y} \in \mathcal{X}$ (premissa)**. Então a estatística T é suficiente e minimal para θ .
- Antes de demonstrar o Teorema, discutiremos sua proposta através de um exemplo.

Exemplo

- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim N(\mu, \sigma^2)$, temos que:

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \theta) &= \frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \left[\underbrace{\sum_{i=1}^n (x_i - \bar{x})^2}_{s_x^2} + n(\bar{x} - \mu)^2 \right]\right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}) \\ &= \frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \left[s_x^2 + n\bar{x}^2 - 2n\bar{x}\mu + n\mu^2 \right]\right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x})\end{aligned}$$

- Então, $\forall \mathbf{x}, \mathbf{y} \in \mathcal{X}$, temos que:

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{y}; \theta)} = \frac{\frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \left[s_x^2 + n\bar{x}^2 - 2n\bar{x}\mu + n\mu^2 \right]\right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x})}{\frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \left[s_y^2 + n\bar{y}^2 - 2n\bar{y}\mu + n\mu^2 \right]\right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{y})}$$

Exemplo

- Continuando

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \boldsymbol{\theta})}{f_{\mathbf{X}}(\mathbf{y}; \boldsymbol{\theta})} = \exp\left\{-\frac{1}{2\sigma^2} \left[s_x^2 - s_y^2 + n(\bar{x}^2 - \bar{y}^2) - 2\mu n(\bar{x} - \bar{y}) \right]\right\} \\ \times \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}) \mathbb{1}_{\mathcal{R}^n}(\mathbf{y})$$

- Logo, $\frac{f_{\mathbf{X}}(\mathbf{x}; \boldsymbol{\theta})}{f_{\mathbf{X}}(\mathbf{y}; \boldsymbol{\theta})}$ não dependerá de $\boldsymbol{\theta}$, se e somente se, $s_x^2 = s_y^2$ e $\bar{x} = \bar{y}$.
- Portanto, $\mathbf{T} = \left(\bar{X}, \sum_{i=1}^n [X_i - \bar{X}]^2 \right)'$ é uma estatística suficiente e minimal para $\boldsymbol{\theta}$.

Demonstração do Teorema (suficiência & minimalidade)

- 1) Suficiência: Sabemos que T é suficiente \leftrightarrow
 $f_{\mathcal{X}}(\mathbf{x}; \theta) = g(t; \theta)h(\mathbf{x})$. Além disso, a estatística T induz uma partição em \mathcal{X} .
- Com efeito, $P = \{A_t : A_t \subseteq \mathcal{X}, \forall t \in B\}$, $A_t = \{\mathbf{x} \in \mathcal{X} : t(\mathbf{x}) = t\}$ e $B = \{t \in \mathcal{R} : t(\mathbf{x}) = t, \text{ para algum } \mathbf{x} \in \mathcal{X}\}$.
- Assim, para cada $A_t, \exists \mathbf{x}_t \in A_T$ e $\exists \mathbf{x} \in \mathcal{X}, t(\mathbf{x}) = t(\mathbf{x}_t)$.

Demonstração do Teorema (suficiência & minimalidade)

- Por outro lado, pelo teorema (suposição), temos que $\frac{f_{\mathbf{X}}(\mathbf{x};\theta)}{f_{\mathbf{X}}(\mathbf{x}_t;\theta)}$ não depende de θ .
- Defina, agora, $h(\mathbf{x}) = \frac{f_{\mathbf{X}}(\mathbf{x};\theta)}{f_{\mathbf{X}}(\mathbf{x}_t;\theta)}$ e $g(t;\theta) = f_{\mathbf{X}}(\mathbf{x}_t;\theta)$ (note que $g : B \rightarrow \mathcal{R}^+$, $t(\mathbf{x}_t) = t$, além do que se f não depender de $t(\cdot)$, t não poderia ser uma estatística suficiente).
- Assim:

$$f_{\mathbf{X}}(\mathbf{x};\theta) = \frac{f_{\mathbf{X}}(\mathbf{x};\theta)}{f_{\mathbf{X}}(\mathbf{x}_t;\theta)} f_{\mathbf{X}}(\mathbf{x}_t;\theta) = h(\mathbf{x})g(t;\theta)$$

- Logo, pelo teorema da fatoração $T = t(\mathbf{X})$ é uma estatística suficiente para θ .
- Obs: note que, a rigor, $f_{\mathbf{X}}(\mathbf{x}_t;\theta) \equiv g^*(t;\theta)h^*(\mathbf{x}_t)$.

Demonstração do Teorema (suficiência & minimalidade)

- 2) Minimalidade: queremos provar que $\forall T'$ suficiente, $\exists g, T = g(T')$.
- Se T' é suficiente, $\exists g', h'$, funções tais que $f_{\mathbf{X}}(\mathbf{x}; \theta) = g'(t'; \theta)h'(\mathbf{x})$.
- Agora consideremos $\mathbf{x}, \mathbf{y} \in \mathcal{X}$, $t'(\mathbf{x}) = t'(\mathbf{y})$, então:

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{y}; \theta)} = \frac{g'(t'(\mathbf{x}); \theta)h'(\mathbf{x})}{g'(t'(\mathbf{y}); \theta)h'(\mathbf{y})} = \frac{h'(\mathbf{x})}{h'(\mathbf{y})},$$

que não depende de θ . Logo, pelo teorema (suposição), $t(\mathbf{x}) = t(\mathbf{y})$.
Ou seja, se $t'(\mathbf{x}) = t'(\mathbf{y}) \rightarrow t(\mathbf{x}) = t(\mathbf{y})$. Portanto, $T = g(T')$.

- Portanto, por 1) e 2), temos que T é suficiente e minimal.

Demonstração do Teorema (suficiência & minimalidade)

- OBS: Nem sempre existe uma estatística suficiente e minimal não trivial (a amostra completa, p.e.).
- Exemplo: Sejam X_1, X_2 uma aa de $X \sim \text{Cauchy}(\theta, 1)$.
- Se \exists uma estatística, digamos T , suficiente e minimal então $\forall \mathbf{x}, \mathbf{y} \in \mathcal{X}$, $t(\mathbf{x}) = t(\mathbf{y})$, teremos que:

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{y}; \theta)} = Q(\mathbf{x}, \mathbf{y}), \forall \theta \in \Theta.$$

Exemplo:

- Contudo, note que

$$\begin{aligned}\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{y}; \theta)} &= \frac{\frac{1}{1+(x_1-\theta)^2} \frac{1}{1+(x_2-\theta)^2}}{\frac{1}{1+(y_1-\theta)^2} \frac{1}{1+(y_2-\theta)^2}} \\ &\Leftrightarrow (1+(y_1-\theta)^2)(1+(y_2-\theta)^2) \\ &\quad - (1+(x_1-\theta)^2)(1+(x_2-\theta)^2)Q(\mathbf{x}, \mathbf{y}) = 0.\end{aligned}$$

- Que tem a forma de um polinômio de 4º grau em θ , ou seja, $a_0 + a_1\theta + a_2\theta^2 + a_3\theta^3 + a_4\theta^4 = 0$, em que $a_i = g(\mathbf{x}, \mathbf{y}), i = 0, 1, 2, 3, 4$.
- Mas isso ocorre, no máximo, para 4 valores de θ , o que é uma contradição, pois deveria valer $\forall \theta \in \Theta$.
- OBS: Veremos uma forma conveniente de obter estatísticas suficientes e minimais, mais adiante.

Estatística ancilar

- Podemos também definir estatísticas com características opostas as estatísticas suficientes, ou seja, que não contenham informações (relevantes) sobre o parâmetro.
- Def: Dizemos que uma estatística $S = s(\mathbf{X})$, $s : \mathcal{R}^n \rightarrow \mathcal{R}$, é dita ancilar para θ , $\theta \in \Theta \subset \mathcal{R}$, se sua distribuição não depende de θ . Ou seja, se

$$S \sim F_\theta \equiv F.$$

- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim U(\theta, \theta + 1)$, $\theta \in \mathcal{R}$ e defina $R = Y_n - Y_1$, Y_i é a i -ésima estatística de ordem.
- Vamos provar que R é uma estatística ancilar para θ .
- Defina $\mathbf{T} = (Y_n - Y_1, \frac{Y_1 + Y_n}{2})' = (R, M)'$.

Estatística ancilar

- Podemos mostrar (exercício) que se $\mathbf{Y} = (Y_1, Y_n)'$ então

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = n(n-1)(y_n - y_1)^{n-2} \mathbb{1}_{(\theta, y_n)}(y_1) \mathbb{1}_{(\theta, \theta+1)}(y_n).$$

- Por outro lado, pelo método do Jacobiano, temos que

$$f_{(R, M)}(r, m; \theta) = n(n-1)r^{n-2} \mathbb{1}_{(0,1)}(r) \mathbb{1}_{(\theta+\frac{r}{2}, \theta+1-\frac{r}{2})}(m) \quad (1)$$

- Além disso, temos (integrando (1) com relação à m) que:

$$f_R(r) = n(n-1)r^{n-2}(1-r) \mathbb{1}_{(0,1)}(r)$$

- Ou seja, $R \sim \text{beta}(n-1, 2)$, que não depende de θ .

- Outra forma de resolver: note que $X \sim U(\theta, \theta + 1)$ pertence à família de localização. Assim, se $Z = X - \theta$, a distribuição de Z não depende de θ .
- Por outro lado, temos que:

$$\begin{aligned}R = Y_n - Y_1 &= \max(X_1, \dots, X_n) - \min(X_1, \dots, X_n) \\&= \max(Z_1 + \theta, \dots, Z_n + \theta) - \min(Z_1 + \theta, \dots, Z_n + \theta) \\&= \max(Z_1, \dots, Z_n) + \theta - \min(Z_1, \dots, Z_n) - \theta \\&= Z_{(n)} - Z_{(1)}\end{aligned}$$

Estatística ancilar

- Exercício: Seja X_1, \dots, X_n uma aa de X , em que X pertence à família de escala. Mostre que:

$$S(\mathbf{X}) = f\left(\frac{X_1}{X_n}\right) + f\left(\frac{X_2}{X_n}\right) + \dots + f\left(\frac{X_{n-1}}{X_n}\right)$$

é uma estatística ancilar para σ^2 (considere que $f(\cdot)$ é contínua).

- Em particular $S(\mathbf{X}) = \frac{X_1 + X_2 + \dots + X_{n-1}}{X_n}$ é ancilar.
- Mostre também que $S = \frac{Y_n - Y_1}{Y_n + Y_1}$ é ancilar para σ^2 .
- Exemplo: X_1, \dots, X_n é uma aa de X , $X \sim \exp(\theta)$,
 $f_X(x; \theta) = \frac{e^{-x/\theta}}{\theta} \mathbb{1}_{(0, \infty)}(x)$
- Exercício: Seja $X_1, \dots, X_n \stackrel{iid}{\sim} N(\mu, \sigma^2)$, σ^2 conhecido. Encontre uma estatística ancilar para μ .

Estatística ancilar

- OBS: Informação (material) ancilar = informação irrelevante com respeito ao parâmetro.
- Vimos que é possível construir funções de estatísticas suficientes que são estatísticas ancilares.
- Isso quer dizer que, apesar de uma estatística suficiente conter toda informação relevante sobre o parâmetro, ela também (pode conter) contém informação não relevante (em termos inferenciais) sobre o parâmetro.

Estatística ancilar

- É como se a informação relevante fosse “contaminada” pela informação ancilar.
- Isto, por sua vez, compromete propriedades ótimas que uma estatística suficiente (poderia apresentar) apresenta, no sentido de conduzir à obtenção de estimadores (pontuais e intervalares) e testes ótimos, como discutiremos mais adiante.

Estatística completa

- Def: Seja $f_T(\cdot; \theta)$, $\theta \in \Theta \subset \mathcal{R}$ a fdp de uma estatística T . A família de distribuições $f_T(\cdot; \theta)$ é dita ser completa se:
 - $E_\theta(g(T)) = 0, \forall \theta \in \Theta, \rightarrow P_\theta(g(T) = 0) = 1$, ou se,
 - $E_\theta(g(T)) = 0, \forall \theta \in \Theta, \rightarrow g(t) = 0, \forall t \in B$ (suporte de T).
- Em particular, dizemos que T é uma estatística completa.
- Note que a definição implica na impossibilidade de se definir funções (estatísticas) ancilares a partir de T (funções de T).

Estatística completa

- Exemplo 1: Seja $X \sim N(0, \sigma^2)$, $\sigma^2 > 0$ e $T = X$.
 - Se $T = X \rightarrow \mathcal{E}(T) = \mathcal{E}(X) = 0$, mas $g(x) = x \neq 0, \forall x \neq 0$.
 - Nesse caso, X não é uma estatística completa.
- Exemplo 2: Sejam $X_1, X_2 \stackrel{iid}{\sim} N(\theta, 1)$, $\theta \in \mathcal{R}$. Defina $T_1 = X_1 + X_2$ e $T_2 = X_1 - X_2$.
- Neste caso, podemos provar que T_1 é uma estatística completa enquanto que T_2 não o é.

Estatística completa

- Dois resultados que ajudam a provar que uma estatística é completa são:
 - a) Seja $h(x; \theta)$ uma função diferenciável com relação à θ e $\frac{\partial h(x; \theta)}{\partial \theta}$ contínua em função de x e θ , então,

$$\begin{aligned} \frac{d}{d\theta} \int_{a(\theta)}^{b(\theta)} h(x; \theta) dx &= h(b(\theta); \theta) \frac{db(\theta)}{d\theta} \\ &\quad - h(a(\theta); \theta) \frac{da(\theta)}{d\theta} + \int_{a(\theta)}^{b(\theta)} \frac{\partial}{\partial \theta} h(x; \theta) dx \end{aligned}$$

Em particular $\frac{d}{d\theta} \int_0^\theta g(x) dx = g(\theta)$.

- b) Se $\sum_{k=1}^{\infty} c_k \theta^k = 0, \forall \theta \in \Theta \subseteq \mathcal{R}, \Theta \neq \emptyset$, então $c_k = 0, \forall k$.

Estatística completa

- Exemplo 1: Seja $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$, $\theta \in (0, 1)$ e defina $T = \sum_{i=1}^n X_i$. Mostre que T é uma estatística completa.
- Queremos provar que, se $\mathcal{E}_\theta(g(T)) = 0 \rightarrow g(T) = 0, \forall t \in B$.
- Sabemos que $T \sim \text{binomial}(n, \theta)$. Então

$$\begin{aligned}\mathcal{E}_\theta(g(T)) &= 0 \rightarrow \sum_{t=0}^n g(t) \binom{n}{t} \theta^t (1-\theta)^{n-t} = 0 \\ &= \sum_{t=0}^n g(t) \binom{n}{t} \left(\frac{\theta}{1-\theta}\right)^t = 0 \\ &= \sum_{t=0}^n g(t) \binom{n}{t} \gamma^t = 0\end{aligned}\tag{2}$$

- Pelo resultado b), se (2) vale, então $g(t) \binom{n}{t} = 0, \forall t \in B \leftrightarrow g(t) = 0, \forall t \in B$, pois $\binom{n}{t} > 0, \forall t \in B$.
- Logo T é uma estatística completa.

Estatística completa

- Exemplo 2: Seja $X_1, \dots, X_n \stackrel{iid}{\sim} U(0, \theta)$, $\theta \in \mathcal{R}^+$ e defina $T = \max(X_1, \dots, X_n)$. Mostre que T é uma estatística completa.
- Sabemos que $h_T(t; \theta) = \frac{nt^{n-1}}{\theta^n} \mathbb{1}_{(0, \theta)}(t)$ (fdp). Assim (lembre que $(n, \theta) > 0$),

$$\mathcal{E}_\theta(T) = 0 \rightarrow \int_0^\theta g(t) \frac{nt^{n-1}}{\theta^n} dt = 0 \rightarrow \int_0^\theta g(t) t^{n-1} dt = 0 \quad (3)$$

- Derivando (7) com relação θ , temos que

$$g(\theta)\theta^{n-1} = 0 \rightarrow g(\theta) = 0, \forall \theta \in \Theta \quad (4)$$

- Note que $B \subseteq \Theta$. Assim, em particular, $g(t) = 0, \forall t \in B$.
- Portanto, T é uma estatística completa.

Teorema de Basu

- Seja T uma estatística suficiente e completa para θ . Então T é estatisticamente independente de qualquer estatística ancilar.
- Prova para o caso discreto: Queremos provar que $P_\theta(S = s, T = t) = P_\theta(S = s)P_\theta(T = t), \forall s, t, \theta$.
- Seja $S = s(\mathbf{X})$ uma estatística ancilar para θ . Logo $f_S(s; \theta) = P_\theta(S = s) \equiv P(S = s)$, não depende de θ .
- Defina, $\forall s \in \mathcal{S}$ (suporte de S), s fixado:

$$g(t) = P_\theta(S = s | T = t) - P_\theta(S = s)$$

que não depende de θ pois,

$P_\theta(S = s | T = t) = \sum_{\mathbf{x} \in \mathcal{X}: s(\mathbf{x})=s} P(\mathbf{X} = \mathbf{x} | T = t(\mathbf{x}))$, (esta última expressão não depende de θ , pois T é suficiente para θ).

Teorema de Basu

- Por outro lado ($\sum_t \equiv \sum_{t \in B} \equiv \sum_{\mathbf{x} \in \mathcal{X}: t(\mathbf{x})=t}$, B é o suporte de T)

$$\begin{aligned}\mathcal{E}_\theta(g(T)) &= \sum_t g(t) P_\theta(T = t) \\ &= \sum_t [P(S = s | T = t) - P(S = s)] P_\theta(T = t) \\ &= \sum_t P(S = s | T = t) P_\theta(T = t) - P(S = s) \underbrace{\sum_t P_\theta(T = t)}_1 \\ &= \sum_t P_\theta(S = s, T = t) - P(S = s) \\ &= P(S = s) - P(S = s) = 0 \\ &\rightarrow \mathcal{E}_\theta(g(T)) = 0\end{aligned}\tag{5}$$

Teorema de Basu

- Como T é uma estatística suficiente e completa, (5) implica que :

$$\begin{aligned}g(T) &\equiv 0 \forall t \in B, \text{ ou seja} \\P(S = s|T = t) - P(S = s) &= 0 \\ \rightarrow P(S = s|T = t) &= P(S = s) \forall t \in B, \text{ e como } s \text{ é arbitrário} \\ P(S = s|T = t) &= P(S = s), \forall t, s, \theta \\ &\quad (\text{ambas expressões independem de } \theta)\end{aligned}$$

- Logo, T e S são estatisticamente independentes.

Exemplos

- Exemplo 1: Seja X_1, \dots, X_n uma aa de $X \sim N(\mu, \sigma^2)$, σ^2 conhecido. Então $T = \bar{X}$ e $S = \sum_{i=1}^n (X_i - \bar{X})^2$ são independentes.
 - Nesse caso, \bar{X} é suficiente e completa (temos que provar a completude) para μ .
 - Por outro lado, $\frac{S}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 \sim \chi_{(n-1)}^2 \rightarrow S \sim \sigma^2 \chi_{(n-1)}^2$.
 - Assim, S é ancilar para μ . Portanto, pelo Teorema de Basu, \bar{X} e S são estatisticamente independentes.
- Exemplo 2: Seja X_1, \dots, X_n uma aa de $X \sim U(0, \theta)$, $\theta > 0$. Então Y_n (já provamos que é suficiente e completa) e $S = \frac{Y_n - Y_1}{Y_1 + Y_n}$ são estatisticamente independentes (exercício).

Voltando à Família Exponencial

- Teorema 1: Seja X_1, \dots, X_n uma aa de $X \sim FE_k(\theta)$, $\theta \in \Theta \subseteq \mathcal{R}^k$ (X pode ser um vetor aleatório). Então a estatística $\mathbf{T} = (T_1, \dots, T_k)'$ é uma estatística suficiente para θ (este resultado também vale para a família exponencial curvada).
Prova: Critério da Fatoração (exercício).
- Teorema 2: Seja X_1, \dots, X_n uma aa de X cuja fdp pode ser escrita como $(FE_1(\theta), \theta \in \Theta \subseteq \mathcal{R})$:

$$\begin{aligned}f_X(x; \theta) &= h(x) \exp \{c(\theta)t(x) + d(\theta)\} \mathbb{1}_A(x) \\ &= h(x) \exp \{\eta t(x) - d_0(\eta)\} \mathbb{1}_A(x).\end{aligned}$$

Então se $\Gamma = \{\eta \in \mathcal{R} : \int_A h(x) \exp \{\eta t(x)\} dx < \infty\}$ contiver algum intervalo aberto em \mathcal{R} então $T = t(\mathbf{X}) = \sum_{i=1}^n t(X_i)$ será completa e minimal.

Voltando à Família Exponencial

- Teorema 3: Seja X_1, \dots, X_n uma aa de X cuja fdp é da forma $(FE_K(\theta))$, $\theta \in \Theta \subseteq \mathcal{R}^k$:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}; \theta) &= h(\mathbf{x}) \exp \left\{ \sum_{j=1}^k c_j(\theta) t_j(\mathbf{x}) + d(\theta) \right\} \mathbb{1}_{A^*}(\mathbf{x}) \\ &= h(\mathbf{x}) \exp \left\{ \sum_{j=1}^k \eta_j t_j(\mathbf{x}) + d_0(\eta) \right\} \mathbb{1}_{A^*}(\mathbf{x}). \end{aligned}$$

Então se $\Gamma = \{ \eta \in \mathcal{R}^k : \int_{A^*} h(\mathbf{x}) \exp \{ \eta t(\mathbf{x}) \} d\mathbf{x} < \infty \}$ contiver algum “retângulo” aberto em \mathcal{R}^k , então

$\mathbf{T} = (t_1(\mathbf{X}), \dots, t_k(\mathbf{X}))' = (\sum_{i=1}^n t_1(X_i), \dots, \sum_{i=1}^n t_k(X_i))$ será completa e minimal, em que A^* é o suporte associado ao vea \mathbf{X} .

Prova: Lehmann & Romano (Testing Statistical Hypothesis).

Voltando à Família Exponencial

- Discussão sobre completitude: Seja $f_X(\cdot, \theta)$ na forma da família exponencial canônica ($\eta \in \mathcal{R}$).
- Seja T a estatística inerente à FE. Queremos provar que se (caso contínuo).

$$\mathcal{E}_\eta(g(T)) = \int_B g(t) \exp\{t\eta + d_0(\eta)\} h_0(t) dt = 0 \rightarrow g(t) = 0 \forall t \in B$$

- Seja $g(t) = g^+(t) - g^-(t), \forall t \in B$, em que $g^+(t) = g(t)\mathbb{1}_{\mathcal{R}^+}(g(t))$ e $g^-(t) = (-g(t))\mathbb{1}_{(\mathcal{R}^-)}(g(t))$. Assim

$$\mathcal{E}_\eta(g(T)) = 0 \rightarrow \int g^+(t) \exp\{t\eta\} h_0(t) dt = \int g^-(t) \exp\{t\eta\} h_0(t) dt$$

$\forall \eta \in N(\eta_0) = \{\eta \in \mathcal{R} : |\eta - \eta_0| < \epsilon\}$, para algum $\epsilon > 0$.

Voltando à Família Exponencial

- Em particular,

$$\rightarrow \int g^+(t) \exp\{t\eta\} h_0(t) dt = \int g^-(t) \exp\{t\eta\} h_0(t) dt = c \quad (6)$$

- Assim $\frac{1}{c}g^+(t) \exp\{t\eta\} h_0(t)$ e $\frac{1}{c}g^-(t) \exp\{t\eta\} h_0(t)$ são fdp's. Por (6) as fgm's dessa fdp's são iguais numa vizinhança de 0. Então, pelo teorema da unicidade, temos que

$$g^+(t) = g^-(t) \rightarrow g(t) = 0 \forall t \in B.$$

Voltando à Família Exponencial

- Com relação à minimalidade (de \mathbf{T}) devemos provar que $\forall \mathbf{x}, \mathbf{y} \in \mathcal{X}$
 $\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{Y}}(\mathbf{y}; \theta)} = Q(\mathbf{x}, \mathbf{y}) \leftrightarrow t(\mathbf{x}) = t(\mathbf{y})$.
- Com efeito, temos que:

$$\begin{aligned} Q(\mathbf{x}, \mathbf{y}; \theta) &= \exp \left\{ \sum_{j=1}^k \eta_j t_j(\mathbf{x}) - \sum_{i=1}^k \eta_j t_j(\mathbf{y}) \right\} \frac{h(\mathbf{x})}{h(\mathbf{y})} \\ &= \exp \left\{ \sum_{j=1}^k \eta_j (t_j(\mathbf{x}) - t_j(\mathbf{y})) \right\} \frac{h(\mathbf{x})}{h(\mathbf{y})}, \end{aligned}$$

o que prova a minimalidade de \mathbf{T} .

Voltando à Família Exponencial

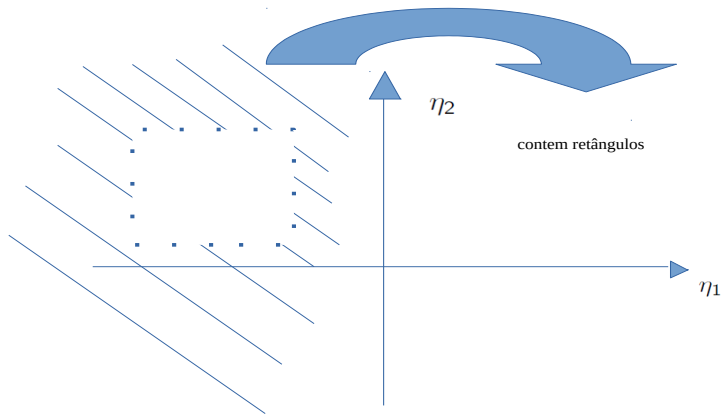
- Exemplo 1: Seja X_1, \dots, X_n uma aa de X , $X \sim N(\mu, \sigma^2)$. Temos que:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}; \boldsymbol{\theta}) &= \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n x_i - n \frac{\mu}{2\sigma^2} \right\} \left(\frac{1}{\sqrt{2\pi}\sigma} \right)^n \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}) \\ &= \exp \left\{ \sum_{j=1}^2 \eta_j t_j(\mathbf{x}) + d_0(\boldsymbol{\eta}) \right\} h(\mathbf{x}), \end{aligned}$$

em que $\eta_1 = -\frac{1}{\sigma^2}$ e $\eta_2 = \frac{\mu}{\sigma^2}$. Graficamente, veja slide seguinte, o espaço paramétrico natural contém retângulos no \mathcal{R}^2 . Assim, por esse fato e como $f_{\mathbf{X}}(\cdot; \boldsymbol{\theta}) \in FE_2(\boldsymbol{\theta})$, temos que

$\mathbf{T} = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2)'$ é uma estatística suficiente, completa e minimal para $\boldsymbol{\theta} = (\mu, \sigma^2)'$.

Representação gráfica (espaço paramétrico)




Voltando à Família Exponencial

- Exemplo 2: Seja X_1, \dots, X_n uma aa de X , $X \sim N(\theta, \theta^2)$. Temos que:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}; \theta) &= \left(\frac{1}{\sqrt{2\pi\theta}} \right)^n \exp \left\{ -\frac{1}{2\theta^2} \sum_{i=1}^n x_i^2 + \frac{1}{\theta} \sum_{i=1}^n x_i - n \right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x}) \\ &= \exp \left\{ \sum_{j=1}^2 \eta_j t_j(\mathbf{x}) + d_0(\eta) \right\} h(\mathbf{x}), \end{aligned}$$

em que $\eta_1 = -\frac{1}{\theta^2}$ e $\eta_2 = \frac{1}{\theta}$. Graficamente, veja slide seguinte, o espaço paramétrico natural não contém retângulos no \mathcal{R}^2 . Assim, não podemos afirmar que a estatística $\mathbf{T} = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2)'$ é uma completa e minimal (embora ela seja suficiente).

Representação gráfica (espaço paramétrico)



Mais exemplos

- Sejam X_1, \dots, X_n uma aa de X , em que
 - a) $X \sim U(0, \theta)$.
 - b) $X \sim U(-\theta, \theta)$.
 - c) $X \sim U(\theta, \theta + 1)$.
- Note que nenhum dos três modelos pertencem à FE.

Mais exemplos

a) Relembrando:

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

Mas

$$\begin{aligned} \prod_{i=1}^n \mathbb{1}_{(0, \theta)}(x_i) = 1 &\Leftrightarrow 0 < x_i < \theta, \forall i \Leftrightarrow 0 < \min(\mathbf{x}) < \max(\mathbf{x}) < \theta \\ &\Leftrightarrow 0 < y_1 < y_n < \theta \Leftrightarrow \mathbb{1}_{(0, \theta)}(y_1) \mathbb{1}_{(y_1, \theta)}(y_n) = 1 \\ &\Leftrightarrow \mathbb{1}_{(0, \theta)}(y_n) \mathbb{1}_{(0, y_n)}(y_1) = 1 \end{aligned}$$

Mais exemplos

a) Já vimos que

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \theta) &= \frac{1}{\theta^n} \prod_{i=1}^n \mathbb{1}_{(-\theta, \theta)}(x_i) = \frac{1}{\theta^n} \mathbb{1}_{(0, \theta)}(y_n) \mathbb{1}_{(0, y_n)}(y_1) \\ &= \frac{1}{\theta^n} \mathbb{1}_{(0, \theta)}(y_1) \mathbb{1}_{(y_1, \theta)}(y_n)\end{aligned}$$

Já vimos que Y_n é suficiente (pág. 15) e completa (pág. 46). Em relação à minimalidade, note que $\forall \mathbf{x}, \mathbf{x}^* \in \mathcal{X}$, temos que

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

que não dependerá de $\theta \leftrightarrow y_n = y_n^*$, em que $y_1^* = \min(\mathbf{x}^*)$, $y_n^* = \max(\mathbf{x}^*)$ e $\mathbf{x}^* = (x_1^*, \dots, x_n^*)'$. Portanto, Y_n também é minimal.

Mais exemplos

- b) Neste caso, temos uma estrutura semelhante ao caso anterior (item a)), com efeito:

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \theta) &= \frac{1}{(2\theta)^n} \prod_{i=1}^n \mathbb{1}_{(-\theta, \theta)}(x_i) = \frac{1}{(2\theta)^n} \prod_{i=1}^n \mathbb{1}_{(0, \theta)}(|x_i|) \\ &= \frac{1}{(2\theta)^n} \mathbb{1}_{(0, \theta)}(r_n) \mathbb{1}_{(0, r_n)}(r_1) = \frac{1}{(2\theta)^n} \mathbb{1}_{(0, \theta)}(r_1) \mathbb{1}_{(r_1, \theta)}(r_n) \\ &= h(\mathbf{x})g(r_n; \theta),\end{aligned}$$

em que $R_n = \max(|X_1|, \dots, |X_n|)$ e $R_1 = \min(|X_1|, \dots, |X_n|)$. Assim, pelo critério da fatoração, temos que R_n é uma estatística suficiente para θ .

Mais exemplos

b) Em relação à minimalidade, note que $\forall \mathbf{x}, \mathbf{x}^* \in \mathcal{X}$, temos que

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{x}^*; \theta)} = \frac{\frac{1}{(2\theta)^n} \mathbb{1}_{(0,\theta)}(r_n) \mathbb{1}_{(0,r_n)}(r_1)}{\frac{1}{(2\theta)^n} \mathbb{1}_{(0,\theta)}(r_n^*) \mathbb{1}_{(0,r_n^*)}(r_1^*)}$$

que não dependerá de $\theta \leftrightarrow r_n = r_n^*$, em que $r_1^* = \min(\mathbf{x}^*)$, $r_n^* = \max(\mathbf{x}^*)$ e $\mathbf{x}^* = (x_1^*, \dots, x_n^*)'$. Portanto, R_n também é minimal.

Mais exemplos

b) Com relação à completude, analogamente ao caso anterior (item a)), temos que:

- Sabemos que, se $R_n = T$, então $h_T(t; \theta) = \frac{nt^{n-1}}{\theta^n} \mathbb{1}_{(0, \theta)}(t)$ (fdp) (provar). Assim (lembre que $(n, \theta) > 0$),

$$\mathcal{E}_\theta(g(T)) = 0 \rightarrow \int_0^\theta g(t) \frac{nt^{n-1}}{\theta^n} dt = 0 \rightarrow \int_0^\theta g(t) t^{n-1} dt = 0 \quad (\forall)$$

- Derivando (7) com relação θ , temos que

$$g(\theta)\theta^{n-1} = 0 \rightarrow g(\theta) = 0, \forall \theta \in \Theta$$

- Note que $B \subseteq \Theta$. Assim, em particular, $g(t) = 0, \forall t \in B$.
- Portanto, R_n também é uma estatística completa.

Mais exemplos

c) Já vimos que

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \theta) &= \prod_{i=1}^n \mathbb{1}_{(\theta, \theta+1)}(x_i) = \mathbb{1}_{(\theta, \theta+1)}(y_1) \mathbb{1}_{(y_1, \theta+1)}(y_n) \\ &= \mathbb{1}_{(\theta, \theta+1)}(y_n) \mathbb{1}_{(\theta, y_n)}(y_1) = h(\mathbf{x})g(\mathbf{t}; \theta).\end{aligned}$$

Logo, pelo critério da fatoração, $\mathbf{T} = (Y_1, Y_n)'$ é uma estatística suficiente. Com relação à minimalidade, $\forall \mathbf{x}, \mathbf{y} \in \mathcal{X}$, note que:

$$\frac{\mathbb{1}_{(\theta, \theta+1)}(y_n) \mathbb{1}_{(\theta, y_n)}(y_1)}{\mathbb{1}_{(\theta, \theta+1)}(y_n^*) \mathbb{1}_{(\theta, y_n^*)}(y_1^*)},$$

que não depende de $\theta \Leftrightarrow \mathbf{T} = \mathbf{T}^*$, em que $\mathbf{T}^* = (Y_1^*, Y_n^*)$, $y_1^* = \min(x_1^*, \dots, x_n^*)$ e $y_n^* = \max(x_1, \dots, x_n)$.

Mais exemplos

c) Com relação à completitude, já vimos que

$$R = Y_n - Y_1 \sim \text{beta}(n - 1, 2).$$

Defina, agora, $R^* = R - \mathcal{E}(R) = R - \frac{n-1}{n+1}$. Portanto, $\mathcal{E}(R^*) = \mathcal{E}(R) - \frac{n-1}{n+1} = 0$ mas $R^* \neq 0$. Assim, \mathbf{T} não é completa.

Invariância

- O conceito de invariância (na estatística) está relacionado com mudanças específicas na distribuição de estatísticas sob certos tipo de transformações.
- Essencialmente, veremos os conceitos de invariância por localização e por escala.
- Sua utilidade está relacionada a demonstração de certos resultados importantes.
- Para sua distinção em relação ao conceito de **equivariância**, veja http://emis.ams.org/journals/RCE/ingles/V29/V29_2_195NobreAzevedo.pdf.

Invariância por localização

- Dizemos que uma estatística, digamos $T = t(\mathbf{X})$, é invariante por localização se $T = t(X_1 + c, \dots, X_n + c) = T + c$, $c \in \mathcal{R}$ (constante)
- Exemplos
 - $T_1 = \bar{X}$.
 - $T_2 = Y_1 = \min(\mathbf{X})$.
 - $T_3 = Y_n = \max(\mathbf{X})$.
 - $T_4 = \frac{Y_1 + Y_n}{2}$.
- Teorema: Seja X_1, \dots, X_n uma aa de X , com fdp $f_X(\cdot; \theta)$, $\theta \in \mathcal{R}$. Se θ for um parâmetro de localização, então

$$T_P = t_P(\mathbf{X}) = \frac{\int_{-\infty}^{\infty} \theta f_{\mathbf{X}}(\mathbf{X}; \theta) d\theta}{\int_{-\infty}^{\infty} f_{\mathbf{X}}(\mathbf{X}; \theta) d\theta} = \frac{\int_{-\infty}^{\infty} \theta \prod_{i=1}^n f_X(X_i; \theta) d\theta}{\int_{-\infty}^{\infty} \prod_{i=1}^n f_X(X_i; \theta) d\theta},$$

é uma estatística invariante por localização.

Invariância por localização

■ OBS:

- 1 T_p é uma estatística (depende somente de \mathbf{X}).
- 2 É o estimador de Pitman (critério para obtenção de estimadores) para θ (θ parâmetro de localização) (pesquisar na literatura do curso).
- 3 É o estimador bayesiano espereança a posteriori (mais do que um critério para obtenção de estimadores) quando $f(\theta) \propto \mathbb{1}_{\mathcal{R}}(\theta)$ (veremos mais adiante).

Invariância por localização

- Demonstração: Temos (considere $-\gamma = c - \theta$) (lembre-se de que http://www.ime.unicamp.br/~cnaber/aula_FLE_Inf_Mest_2S_2019.pdf página 4) que:

$$\begin{aligned} & t_p(x_1 + c, \dots, x_n + c) \\ = & \frac{\int_{-\infty}^{\infty} \theta \prod_{i=1}^n f_X(x_i + c; \theta) d\theta}{\int_{-\infty}^{\infty} \prod_{i=1}^n f_X(x_i + c; \theta) d\theta} = \frac{\int_{-\infty}^{\infty} \theta \prod_{i=1}^n g(x_i + c - \theta) d\theta}{\int_{-\infty}^{\infty} \prod_{i=1}^n g(x_i + c - \theta) d\theta} \\ = & \frac{\int_{-\infty}^{\infty} (c + \gamma) \prod_{i=1}^n g(x_i - \gamma) d\gamma}{\int_{-\infty}^{\infty} \prod_{i=1}^n g(x_i - \gamma) d\gamma} = c + \frac{\int_{-\infty}^{\infty} \gamma \prod_{i=1}^n f_X(x_i; \gamma) d\gamma}{\int_{-\infty}^{\infty} \prod_{i=1}^n f_X(x_i; \gamma) d\gamma} \\ = & c + t_p. \end{aligned}$$

Invariância por localização

- Exemplo Seja X_1, \dots, X_n uma aa de $X \sim U(\theta - a, \theta + a)$, $\theta \in \mathcal{R}$, $a \in \mathcal{R}^+$ (conhecido). Temos que

$$\begin{aligned} T_p &= \frac{\int_{-\infty}^{\infty} \theta \frac{1}{(2a)^n} \prod_{i=1}^n \mathbf{1}_{(\theta-a, \theta+a)}(x_i) d\theta}{\int_{-\infty}^{\infty} \frac{1}{(2a)^n} \prod_{i=1}^n \mathbf{1}_{(\theta-a, \theta+a)}(x_i) d\theta} = \frac{\int_{-\infty}^{\infty} \theta \mathbf{1}_{(y_n-a, y_1+a)}(\theta) d\theta}{\int_{-\infty}^{\infty} \mathbf{1}_{(y_n-a, y_1+a)}(\theta) d\theta} \\ &= \frac{\frac{\theta^2}{2} \Big|_{y_n-a}^{y_1+a}}{\theta \Big|_{y_n-a}^{y_1+a}} = \frac{1}{2} \frac{(y_1+a)^2 - (y_n-a)^2}{y_1 - y_n + 2a} \\ &= \frac{1}{2} \frac{y_1^2 - y_n^2 + 2y_1a + 2y_na + a^2 - a^2}{y_1 - y_n + 2a} = \frac{1}{2} \frac{(y_1 + y_n)(y_1 - y_n + 2a)}{y_1 - y_n + 2a} \\ &= \frac{y_1 + y_n}{2}. \end{aligned}$$

Temos que $T_p = \frac{Y_1 + Y_n}{2}$ é o estimador de Pitman para θ . Exercício: calcular $\mathcal{E}(T_p)$ e $\mathcal{V}(T_p)$.

Invariância por escala

- Def: Uma estatística $T = t(\mathbf{X})$ é invariante por escala, se $T^* = t(cX_1, \dots, cX_n) = ct(\mathbf{X})$, em que $c \in \mathcal{R}$ (constante).
- Exemplos:
 - $T_1 = \bar{X}$.
 - $T_2 = S_X = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$
 - $T_3 = Y_n - Y_1$.
 - $T_4 = \frac{S_X^2}{\bar{X}}$.
- Teorema: Seja X_1, \dots, X_n uma aa de X , com fdp $f_X(\cdot; \theta)$, $\theta \in \mathcal{R}^+$, θ parâmetro de escala. Então

$$T_p = \frac{\int_0^\infty \frac{1}{\theta^2} f_{\mathbf{X}}(\mathbf{x}; \theta) d\theta}{\int_0^\infty \frac{1}{\theta^3} f_{\mathbf{X}}(\mathbf{x}; \theta) d\theta} = \frac{\int_0^\infty \frac{1}{\theta^2} \prod_{i=1}^n f_X(X_i; \theta) d\theta}{\int_0^\infty \frac{1}{\theta^3} \prod_{i=1}^n f_X(X_i; \theta) d\theta},$$

é uma estatística invariante por escala.

Invariância por escala

- Dem: Temos que:

$$t_p(\mathbf{x}) = \frac{\int_0^\infty \frac{1}{\theta^2} \prod_{i=1}^n f_X(x_i; \theta) d\theta}{\int_0^\infty \frac{1}{\theta^3} \prod_{i=1}^n f_X(x_i; \theta) d\theta}$$

- Assim, fazendo $(\gamma = \frac{\theta}{c} \rightarrow d\gamma = \frac{d\theta}{c})$, vem que:

$$\begin{aligned} t_p(cx_1, \dots, cx_n) &= \frac{\int_0^\infty \frac{1}{\theta^2} \prod_{i=1}^n f_X(cx_i; \theta) d\theta}{\int_0^\infty \frac{1}{\theta^3} \prod_{i=1}^n f_X(cx_i; \theta) d\theta} = \frac{\int_0^\infty \frac{1}{\theta^2} \prod_{i=1}^n \frac{1}{\theta} h\left(\frac{cx_i}{\theta}\right) d\theta}{\int_0^\infty \frac{1}{\theta^3} \prod_{i=1}^n \frac{1}{\theta} h\left(\frac{cx_i}{\theta}\right) d\theta} \\ &= c \frac{\int_0^\infty \frac{1}{\gamma^2} \prod_{i=1}^n \frac{1}{\gamma} h\left(\frac{x_i}{\gamma}\right) d\gamma}{\int_0^\infty \frac{1}{\gamma^3} \prod_{i=1}^n \frac{1}{\gamma} h\left(\frac{x_i}{\gamma}\right) d\gamma} = c \frac{\int_0^\infty \frac{1}{\theta^2} \prod_{i=1}^n f_X(x_i; \theta) d\theta}{\int_0^\infty \frac{1}{\theta^3} \prod_{i=1}^n f_X(x_i; \theta) d\theta} \\ &= ct_p(\mathbf{x}). \end{aligned}$$

Logo, $T_p = t_p(\mathbf{X})$ é uma estatística invariante por escala.

Invariância por escala

- Exemplo 2: Seja X_1, \dots, X_n uma aa de $X \sim U(0, \theta)$, $\theta \in \mathcal{R}^+$. Temos que:

$$\begin{aligned} T_p &= \frac{\int_0^\infty \frac{1}{\theta^2} \frac{1}{\theta^n} \mathbf{1}_{(y_n, \infty)}(\theta) \mathbf{1}_{(0, y_n)}(y_1) d\theta}{\int_0^\infty \frac{1}{\theta^3} \frac{1}{\theta^n} \mathbf{1}_{(y_n, \infty)}(\theta) \mathbf{1}_{(0, y_n)}(y_1) d\theta} = \frac{\int_{y_n}^\infty \frac{1}{\theta^{n+2}} d\theta}{\int_{y_n}^\infty \frac{1}{\theta^{n+3}} d\theta} = \frac{-\frac{\theta^{-n-1}}{n+1} \Big|_{y_n}^\infty}{-\frac{\theta^{-n-2}}{n+2} \Big|_{y_n}^\infty} \\ &= \frac{y_n^{-n-1}/(n+1)}{y_n^{-n-2}/(n+2)} = y_n \frac{n+2}{n+1} \end{aligned}$$

Assim, $Y_n \frac{n+2}{n+1}$ é uma estatística invariante por escala. Exercício: Calcular $\mathcal{E}(t_p(\mathbf{X}))$ e $\mathcal{V}(t_p(\mathbf{X}))$.

Obs: Se \exists uma estatística suficiente, digamos $T = t(\mathbf{X})$, então

$T_p = t_p(\mathbf{X})$ será função de T , em ambos os casos (localização e escala).

Prova: exercício.

Princípio da invariância

- Seja $\mathbf{X} = (X_1, \dots, X_n)'$ uma aa de $X \sim f_X(\cdot, \theta)$, $\theta \in \Theta$ e seja $\mathbf{Y} = g(\mathbf{X})$ tem distribuição na mesma classe (por exemplo, ambas tem distribuição normal). Então dizemos que \mathbf{X} é invariante pela transformação g , $g : \mathcal{X} \rightarrow \mathcal{X}$.
- Exemplo 1: Seja $X \sim N(\mu, \sigma^2)$, $Y = g(X) = aX + b \sim N(a\mu + b, a^2\sigma^2)$. Então a família $X(f_X(\cdot; \theta) \sim N(\mu, \sigma^2))$ é invariante a transformação lineares.
- Exemplo 2: Seja $X \sim \text{binomial}(n, \theta)$ e $Y = n - X \sim \text{binomial}(n, 1 - \theta)$. Então a família $X(f_X(\cdot; \theta) \sim \text{binomial}(n, \theta))$ é invariante à transformação $Y = n - X$.

Princípio da invariância

- Def: A classe G de transformações $g : \{\mathcal{X} \rightarrow \mathcal{X}\}$ é chamado de grupo de transformações de \mathcal{X} se
 - 1 $\forall g \in G, \exists g' \in G, (g \circ g')(x) = g(g'(x)) = x$ inversa
 - 2 $\forall g, g' \in G (g \circ g') \in G$ (fechada por composição).
 - 3 $\exists g_0 \in G, g_0(x) = x$ (identidade).
- Def: Seja $F = \{f_{\mathbf{X}}(; \theta), \theta \in \Theta\}$, o conjunto de distribuições de \mathbf{X} e seja G um grupo de transformação sobre \mathcal{X} . Dizemos que F é invariante sob G , se $\forall \theta \in \Theta$ e $g \in G$,
 $Y = g(\mathbf{X}) \sim f_{\mathbf{Y}}(\mathbf{y}; \theta'), \theta' \in \Theta$, desde que $\mathbf{X} \sim f_{\mathbf{X}}(\mathbf{x}; \theta)$.

Princípio da invariância

- Exemplo: Seja X_1, \dots, X_n uma aa de $X, X \sim N(\mu, \sigma^2)$. Defina $G = \{g : \mathcal{X} \rightarrow \mathcal{X}\}$, $g(\mathbf{X}) = (aX_1 + b, \dots, aX_n + b)$. Então G satisfaz as condições de grupo e $F = \{f_{\mathbf{X}}(\cdot; \theta), \theta \in \Theta\}$, $f_{\mathbf{X}}(\mathbf{x}; \theta) \sim N(\mu, \sigma^2)$ é invariante sob G .
- Note que:

$$f_{\mathbf{X}}(\mathbf{x}; \theta) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x})$$

- É possível demonstrar (pela fgm), que:

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = \frac{1}{(2\pi a^2 \sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2a^2 \sigma^2} \sum_{i=1}^n (y_i - (a\mu + b))^2 \right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{y})$$

- Exercício: Verificar que as condições 1), 2) e 3) são satisfeitas, neste caso.