

# 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  $\boldsymbol{\theta}$ .

# Introdução

- Def: Uma função  $T = t(\mathbf{X}) : \mathcal{X} \rightarrow \mathcal{R}$  é dita ser uma estatística. Ela não pode depender do parâmetro  $\theta$ .
- A informação que a estatística  $T$  contem sobre  $\theta$  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

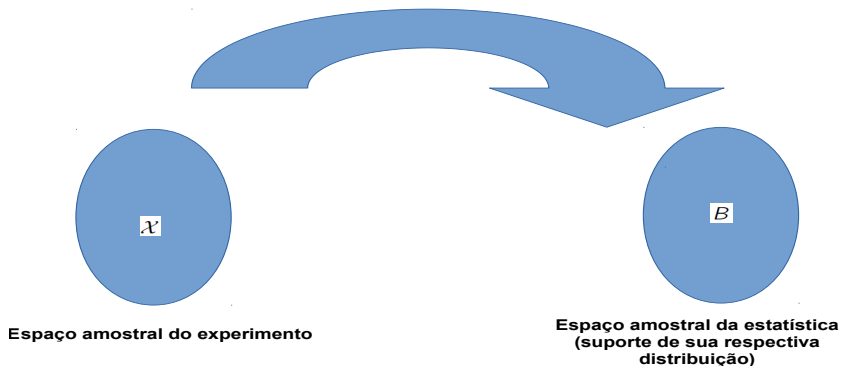
- Defina o seguinte conjunto  $A_t = \{\mathbf{x} \in \mathcal{X} : t(\mathbf{x}) = t\}$ .
- Observe que os conjuntos  $A_t$ 's ( $A_t \subset \mathcal{X}$ ) formam uma partição de  $\mathcal{X}$  pois

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

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

- $\mu$  (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

- $\sigma^2$  (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  $\theta$ , 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  $\theta$  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  $\theta$ , 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  $\theta$  (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:

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

# Suficiência

- 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  $\theta$ ,  $T$  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:

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

# Suficiência

- 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  $\theta$ ,  $T$  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

$$P_{\theta}(T = t) = 0, \forall t \in \mathcal{T}(\text{espaço associado a distribuição } T), \forall \theta \in \Theta.$$

- Teorema: Seja  $q_T(t; \theta)$  a fdp de  $T = t(\mathbf{X})$ . Então  $T$  é suficiente para  $\theta$ , se e somente se  $\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{q_T(t; \theta)}$  não depender de  $\theta$ , 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  $\theta$ .

# 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  $\theta$  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  $\theta$  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  $\theta$ , para que  $T$  seja suficiente para  $\theta$ .

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

# Exemplo 1

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

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

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  $\theta$ .

## 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

$$\mathbf{T} = \left( \bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2 \right)'$$

é uma estatística suficiente para  $\theta$ .

# Suficiência

## ■ Resultados

- a) Se  $T_1 = g(T_2)$  e  $T_1$  é uma estatística suficiente para  $\theta$ , 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  $\theta$ , se e somente se  $T_2$  o for.

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

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

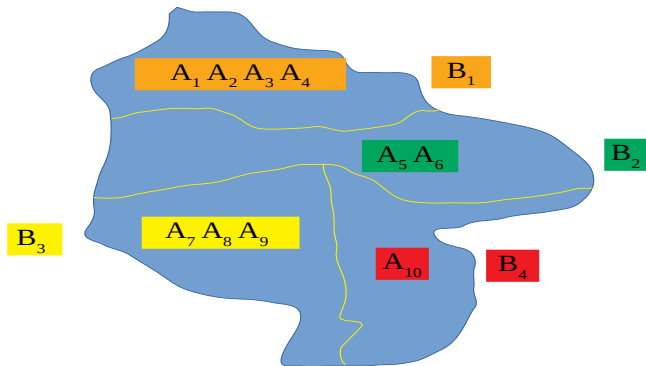
## Exemplo 3

- 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  $\theta$ .
  - 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  $\theta$  (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  $\theta$ ?
- 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  $\theta$ , 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  $X_i \stackrel{iid}{\sim} N(\theta, \sigma^2)$ ,  $\sigma^2$  conhecido. Podemos provar que  $T = \bar{X}$  é suficiente e minimal para  $\theta$ .
- Seja, também,  $T' = (\bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2)$ . Podemos provar que  $T'$  é suficiente para  $\theta$ , 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  $\theta$ , 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  $\theta$ .
- 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:

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

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

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



# Exemplo

- Continuando

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

- Logo,  $\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{y}; \theta)}$  não dependerá de  $\theta$ , 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  $\theta$ .

# 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  $\theta$ .
- 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  $\theta$ .
- 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  $\theta$ . 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.

## Cont.

- Obs: note que duas funções são iguais “quando têm o mesmo domínio, o mesmo contradomínio e a mesma regra de correspondência.”
- No caso de razão de funções indicadoras, podemos utilizar a definição acima, por exemplo:

$$\frac{f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{x}^*; \theta)} = \frac{l_{(g_1(\mathbf{x}), g_2(\mathbf{x}))}(\theta)}{l_{(g_1(\mathbf{x}^*), g_2(\mathbf{x}^*))}(\theta)}$$

não dependerá de  $\theta$  se, e somente se

$$l_{(g_1(\mathbf{x}), g_2(\mathbf{x}))}(\theta) = l_{(g_1(\mathbf{x}^*), g_2(\mathbf{x}^*))}(\theta),$$

ou seja, se e somente se  $g_i(\mathbf{x}) = g_i(\mathbf{x}^*)$ ,  $i = 1, 2$  ( $\forall \theta \in \Theta$ ), em que  $g_i(\mathbf{X})$  são estatísticas,  $i = 1, 2$ .

# 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

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

- Que tem a forma de um polinômio de 4º grau em  $\theta$ , 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  $\theta$ , 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  $\theta$ ,  $\theta \in \Theta \subset \mathcal{R}$ , se sua distribuição não depende de  $\theta$ . 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  $\theta$ .
- 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  $\theta$ .

# Estatística ancilar

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

# 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  $f_T(.,; \theta), \theta \in \Theta \subset \mathcal{R}$  a fdp de uma estatística  $T$ . A família de distribuições  $f_T(.,; \theta)$  é dita ser completa se:
  - $\mathcal{E}_\theta(g(T)) = 0, \forall \theta \in \Theta, \rightarrow P_\theta(g(T) = 0) = 1$ , ou se,
  - $\mathcal{E}_\theta(g(T)) = 0, \forall \theta \in \Theta, \rightarrow g(t) = 0, \forall t \in B$  (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  $\theta$  e  $\frac{\partial h(x; \theta)}{\partial \theta}$  contínua em função de  $x$  e  $\theta$ , 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  $c_k = 0, \forall k$ .



## Cont.

- Especificamente, para a verificação da completitude, as funções  $g(\cdot)$  devem ser tais que:  $\mathcal{E}(g(T)) = \int_B g(t)f_T(t)dt = 0$ , portanto  $|g(t)f_T(t)| < c, \forall t \in B$ .
- Para  $B = (-\infty, b(\theta))$ , temos que

$$\begin{aligned} & \int_{-\infty}^{b(\theta)} g(t)f_T(t)dt \rightarrow \lim_{a \rightarrow -\infty} \int_a^{b(\theta)} g(t)f_T(t)dt \\ \rightarrow & \frac{d}{d\theta} \int_{-\infty}^{b(\theta)} g(t)f_T(t)dt = g(b(\theta))f_T(b(\theta))\frac{db(\theta)}{d\theta} \\ & - \lim_{a \rightarrow -\infty} g(b(\theta))f_T(b(\theta))\frac{da}{d\theta} = g(b(\theta))f_T(b(\theta))\frac{db(\theta)}{d\theta} \end{aligned}$$

- Analogamente, para  $B = (a(\theta), \infty)$ , temos que

$$\frac{d}{d\theta} \int_{a(\theta)}^{\infty} g(t)f_T(t)dt = -g(a(\theta))f_T(a(\theta))\frac{da(\theta)}{d\theta}$$

# 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

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

# Estatística completa

- 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  $(n, \theta) > 0$ ),

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

- Derivando (3) com relação  $\theta$ , 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  $\theta$ . 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  $\theta$ . Logo  $f_S(s; \theta) = P_{\theta}(S = s) \equiv P(S = s)$ , não depende de  $\theta$ .
- 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  $\theta$  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  $\theta$ , pois  $T$  é suficiente para  $\theta$ ).

# 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 :

$$g(T) \equiv 0 \forall t \in B, \text{ ou seja}$$

$$P(S = s | T = t) - P(S = s) = 0$$

$$\rightarrow P(S = s | T = t) = P(S = s) \forall t \in B, \text{ e como } s \text{ é arbitrário}$$

$$P(S = s | T = t) = P(S = s), \forall t, s, \theta$$

(ambas expressões independem de  $\theta$ )

- Logo,  $T$  e  $S$  são estatisticamente independentes.

# Exemplos

- Exemplo 1: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim N(\mu, \sigma^2)$ ,  $\sigma^2$  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  $\mu$ .
  - 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  $\mu$ . 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  $\theta$  (este resultado também vale para a família exponencial curvada).  
Prova: Critério da Fatoração (exercício).

## Voltando à Família Exponencial

- Teorema 2: Seja  $X_1, \dots, X_n$  uma aa de  $X$  cuja fdp pode ser escrita como  $(FE_1(\theta), \theta \in \Theta \subseteq \mathcal{R})$ :

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

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

Prova(s): 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

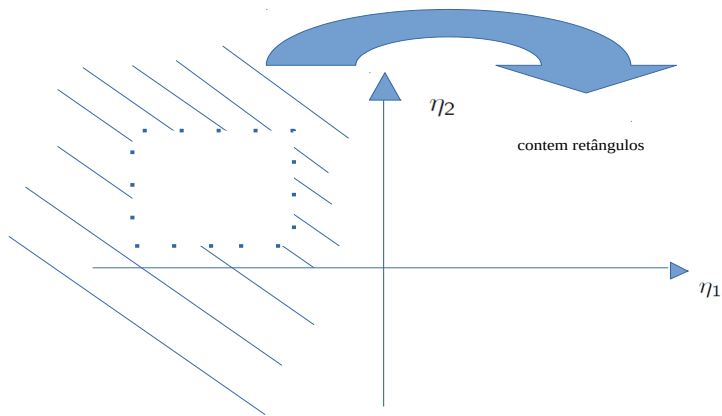
- Exemplo 1: Seja  $X_1, \dots, X_n$  uma aa de  $X$ ,  $X \sim N(\mu, \sigma^2)$ . Temos que:

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

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)





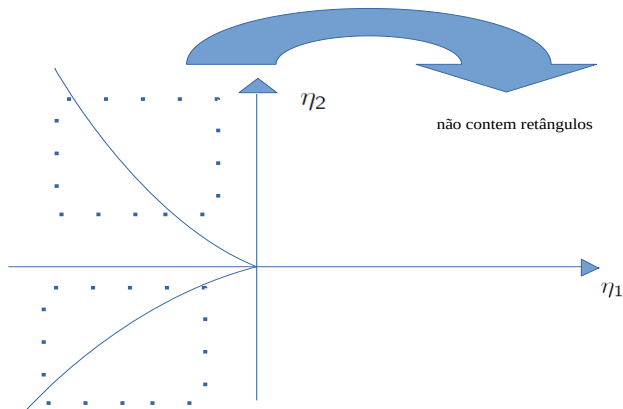
## Voltando à Família Exponencial

- 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

$$\prod_{i=1}^n \mathbb{1}_{(0, \theta)}(x_i) = 1 \iff 0 < x_i < \theta, \forall i \iff 0 < \min(\mathbf{x}) < \max(\mathbf{x}) < \theta$$

$$\iff 0 < y_1 < y_n < \theta \iff \mathbb{1}_{(0, \theta)}(y_1) \mathbb{1}_{(y_1, \theta)}(y_n) = 1$$

$$\iff \mathbb{1}_{(0, \theta)}(y_n) \mathbb{1}_{(0, y_n)}(y_1) = 1$$

## Mais exemplos

a) Já vimos que

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

Também já vimos que  $Y_n$  é suficiente (pág. 18) e completa (pág. 50). 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  $\theta$ .

## 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  $(n, \theta) > 0$ ),

$$\mathcal{E}_\theta(g(T)) = 0 \rightarrow \int_0^\theta g(t) \frac{nt^{n-1}}{\theta^n} dt = 0 \rightarrow \int_0^\theta g(t) t^{n-1} dt = 0 \quad (7)$$

- Derivando (7) com relação  $\theta$ , 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,  $\mathcal{E}(R^*) = \mathcal{E}(R) - \mathcal{E}(R) = 0$  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 [aqui](#).

# 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  $\theta$  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  $T_p$  é o estimador de Pitman (critério para obtenção de estimadores) para  $\theta$  ( $\theta$  parâmetro de localização) (pesquisar na literatura do curso).
- 3  $T_p$  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 [aqui](#) 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

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

Temos que  $T_p = \frac{Y_1 + Y_n}{2}$  é o estimador de Pitman para  $\theta$ . 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  $f_X(\cdot; \theta)$ ,  $\theta \in \mathcal{R}^+$ ,  $\theta$  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 chamada 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  $F = \{f_{\mathbf{X}}(\cdot; \theta), \theta \in \Theta\}$ , 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:

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

# Princípio da invariância

- É possível demonstrar (pela fgm), que:

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

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