

# Métodos de estimação (pontual)

Prof. Caio Azevedo

# Introdução

- Nosso objetivo é inferir (conjecturar a respeito do verdadeiro (ou verdadeiros) valor(es) de  $\theta$  - possivelmente um vetor), ou seja, a respeito do parâmetro de interesse.
- Inferência Estatística: chegar à conclusões através de procedimentos estatísticos. Especificamente, com base em uma amostra, desejamos inferir a respeito do parâmetro  $\theta$  associado à uma população de interesse.

# Introdução

- **Inferência indutiva:** com base em sequências de premissas, chega-se a conclusões de interesse, através de nexos causais lógicas.
- **Inferência dedutiva:** com base em uma parte, obtém-se conclusões para o todo (esta é a que será abordada no curso).
- Primeiro passo: estimação pontual - obter uma estimativa, a mais acurada/precisa possível, com base em um estimador.
- Estimador: é uma estatística da qual se espera boas (ótimas) propriedades, em termos dos objetivos inferenciais.

# Estrutura

- Seja  $X_1, \dots, X_n$  uma aa de  $X$ ,  $X \sim f_X(\cdot; \theta)$ ,  $\theta \in \Theta \subset \mathcal{R}^k$ . O objetivo é construir um estimador para  $\tau(\theta) = (\tau_1(\theta), \dots, \tau_r(\theta))'$ ,  $r \leq k$
- Estimador: dizemos que  $\hat{\theta} \equiv \hat{\theta}(\mathbf{X}) : \mathcal{X} \rightarrow B \subset \mathcal{R}$ . Ou seja, um estimador é uma estatística (de preferência com o maior número de boas propriedades possível), que tem por objetivo inferir a respeito de  $\theta$  (espera-se que  $B \subset \Theta$ ).
- Estimativa:  $\tilde{\theta} \equiv \tilde{\theta}(\mathbf{x})$ : valor numérico do estimador para uma amostra observada,  $\mathbf{x} = (x_1, \dots, x_n)'$ .
- Podemos estar interessados em uma função de  $\theta$ , digamos  $\tau(\theta)$  ou num vetor (de funções)  $\theta = (\theta_1, \dots, \theta_k)'$  ou  $(\tau(\theta) = (\tau_1(\theta), \dots, \tau_r(\theta))'$ .

# Características e qualidade dos estimadores

- Distribuição:  $f_{\hat{\theta}}(\hat{\theta}; \theta)$ .
- Valor esperado:  $\mathcal{E}_{\theta}(\hat{\theta})$  (mais próximo do verdadeiro valor, possível).
- Vício:  $\mathcal{B}_{\theta}(\hat{\theta}) = \mathcal{E}_{\theta}(\hat{\theta} - \theta) = \mathcal{E}_{\theta}(\hat{\theta}) - \theta$  (menor possível).
- Variância:  $\mathcal{V}_{\theta}(\hat{\theta})$  (menor possível).
- Erro quadrático médio (EQM):  
 $\mathcal{EQM}_{\theta}(\hat{\theta}) = \mathcal{E}[(\hat{\theta} - \theta)^2] = \mathcal{B}_{\theta}(\hat{\theta})^2 + \mathcal{V}_{\theta}(\hat{\theta})$  (menor possível) (prova do resultado - exercício).
- Raiz quadrada do Erro quadrático médio:  
 $\mathcal{RQEM}_{\theta}(\hat{\theta}) = \sqrt{\mathcal{EQM}_{\theta}(\hat{\theta})}$  (menor possível).



# Características e qualidade dos estimadores

- Valor absoluto do vício relativo:  $\mathcal{VA}\mathcal{VR}_\theta(\hat{\theta}) = \frac{|\mathcal{B}_\theta(\hat{\theta})|}{|\theta|}$  (menor possível).
- Vício relativo:  $\mathcal{VR}_\theta(\hat{\theta}) = \frac{\mathcal{B}_\theta(\hat{\theta})}{|\theta|}$  (menor possível).
- Consistência:  $\hat{\theta}_n \xrightarrow[n \rightarrow \infty]{P} \theta = \lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| > \epsilon) = 0$
- Convergência em distribuição:  $\hat{\theta} \xrightarrow[n \rightarrow \infty]{D} D(\theta)$ .

# Características e qualidade dos estimadores


- Espera-se que estimadores sejam funções, caso existam, de estatísticas suficientes, completas e minimais, pois:
  - Suficiente: carrega toda a informação relevante.
  - Completa: não possui material ancilar (contaminação com informações que não dizem respeito ao parâmetro).
  - Minimal: máxima redução possível.
  - Dessa forma, é esperado que tais estimadores tenham boas (ótimas propriedades).
- Não faz sentido construir estimadores com base em estatísticas ancilares, pois elas não trazem informações a respeito do parâmetro.

# População ( $N = 1.000.000$ , $\mu = 8$ ) e amostra ( $n = 100$ )





# População e amostra: fonte



(A) - Muito acurado, mas pouco preciso; (B) Pouco acurado e pouco preciso; (C) Muito acurado e muito preciso; (D) Pouco acurado e muito preciso.

# Métodos de estimação (ME)

- É impossível construir um estimador uniformemente ( $\forall F_{\mathbf{X}}(\cdot; \theta)$  e/ou  $\forall \theta \in \Theta$ ) melhor do que todos os outros.
- Se  $X_i \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$ . Seja  $\hat{\theta} = 0,4$ . Este estimador será o melhor sempre que  $\theta = 0,4$  mas, provavelmente, será muito ruim  $\forall \theta \neq 0,4$ .
- ME: mecanismos que seguem alguma definição que (geralmente, com propriedades boas ou ótimas, em algum sentido).
- Dois tipos, basicamente:
  - Métodos genéricos baseados em critérios específicos: métodos dos momentos, máxima verossimilhança, mínimos quadrados.
  - Métodos que buscam estimadores ótimos: estimador não viciado de variância uniformemente mínima, estimador de Bayes, minimização do EQM.

# Métodos dos momentos

- Baseia-se no fato, sob certas condições, de que

$$\frac{1}{n} \sum_{i=1}^n X_i^r \xrightarrow[n \rightarrow \infty]{P} \mathcal{E}(X^r), r = 1, 2, \dots$$

- Deve-se, em relação à  $\theta \in \Theta \subset \mathfrak{R}^k$ , resolver o seguinte sistema de equações:

$$\mathcal{E}(X) = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\mathcal{E}(X^2) = \frac{1}{n} \sum_{i=1}^n X_i^2$$

⋮

$$\mathcal{E}(X^k) = \frac{1}{n} \sum_{i=1}^n X_i^k$$

# Métodos dos momentos

- Principais características:
  - Não, necessariamente, leva à estimadores ótimos.
  - Em geral são facilmente obtíveis.
  - Nem sempre é possível obter distribuições/momentos, de forma exata.
  - Nem sempre os EMM são funções de estatísticas suficientes (completas e minimais).
  - Podem ser viciados.
  - As vezes precisamos utilizar momentos de ordem superior ( $k$ ), pois momentos de ordem inferior ( $< k$ ) podem não ser úteis.

## Exemplo 1: $Bernoulli(\theta)$

- Seja  $X_1, \dots, X_n$  uma aa de  $X \sim Bernoulli(\theta)$ ,  $\theta \in (0, 1)$ .
- Temos que:

$$\mathcal{E}(X) = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

- Logo  $\bar{X}$  é o EMM de  $\theta$ .
- Além disso  $\mathcal{E}(\hat{\theta}) = \frac{1}{n} \sum_{i=1}^n \mathcal{E}(X_i) = \theta$  (não viciado) e  $\mathcal{V}(\hat{\theta}) = \frac{1}{n^2} \sum_{i=1}^n \mathcal{V}(X_i) = \frac{\theta}{n}$  ( $\mathcal{V}(\hat{\theta}) \xrightarrow{n \rightarrow \infty} 0$ ).
- Além disso,  $n\hat{\theta} \sim \text{binomial}(n, \theta)$ .

## Exemplo 2: $\exp(\theta)$

- Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \exp(\theta)$ ,  $\theta \in (0, \infty)$   
( $f_X(x; \theta) = \frac{1}{\theta} \exp\{-\frac{x}{\theta}\} \mathbb{1}_{(0, \infty)}(x)$ ).
- Temos que:

$$\mathcal{E}(X) = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

- Logo  $\bar{X}$  é o EMM de  $\theta$ .
- Além disso  $\mathcal{E}(\hat{\theta}) = \frac{1}{n} \sum_{i=1}^n \mathcal{E}(X_i) = \theta$  (não viciado) e  
 $\mathcal{V}(\hat{\theta}) = \frac{1}{n^2} \sum_{i=1}^n \mathcal{V}(X_i) = \frac{\theta^2}{n}$  ( $\mathcal{V}(\hat{\theta}) \xrightarrow{n \rightarrow \infty} 0$ ).
- Também,  $\hat{\theta} \sim \text{gama}(n, \theta/n)$  ( $X \sim \text{gama}(a, b)$ ,  $a, b \in (0, \infty)$ ), então  
 $f_X(x; \theta) = \frac{1}{\Gamma(a)b} x^{a-1} \exp\{-\frac{x}{b}\} \mathbb{1}_{(0, \infty)}(x)$ .

## Exemplo 3: $N(\mu, \sigma^2)$

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

$$\begin{cases} \mathcal{E}(X) = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X} \\ \mathcal{E}(X^2) = \frac{1}{n} \sum_{i=1}^n X_i^2 \rightarrow \hat{\mu}^2 + \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 \\ \rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \end{cases}$$

- Assim,  $\bar{X}$  e  $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  são, respectivamente, os EMM de  $\mu$  e  $\sigma^2$ .
- Obs: usualmente usa-se a seguinte notação  $\bar{X}_r = \frac{1}{n} \sum_{i=1}^n X_i^r$ .

## Exemplo 3: $N(\mu, \sigma^2)$

- Além disso, temos que  $\bar{X} \sim N(\mu, \sigma^2/n)$  e  $\frac{n\hat{\sigma}^2}{\sigma^2} \sim \chi^2_{(n-1)}$ .
- Além disso:
  - $\mathcal{E}(\hat{\mu}) = \mu$  (não viciado) e  $\mathcal{V}(\hat{\mu}) = \frac{\sigma^2}{n}$  ( $\mathcal{V}(\hat{\mu}) \xrightarrow{n \rightarrow \infty} 0$ ),
  - $\mathcal{E}(\hat{\sigma}^2) = \frac{n-1}{n}\sigma^2$  (viciado),  $\mathcal{B}(\hat{\sigma}^2) = \frac{-\sigma^2}{n}$  ( $\mathcal{B}(\hat{\sigma}^2) \xrightarrow{n \rightarrow \infty} 0$ ),  
 $\mathcal{V}(\hat{\sigma}^2) = \frac{2(n-1)}{n^2}(\sigma^2)^2$  ( $\mathcal{V}(\hat{\sigma}^2) \xrightarrow{n \rightarrow \infty} 0$ ) e  
 $\mathcal{EQM}(\hat{\sigma}^2) = \frac{(2n-1)(\sigma^2)^2}{n^2}$  ( $\mathcal{EQM}(\hat{\sigma}^2) \xrightarrow{n \rightarrow \infty} 0$ ).



## Exemplo 4: $U(0, \theta)$

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

$$\mathcal{E}(X) = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \frac{\hat{\theta}}{2} = \bar{X} \rightarrow \hat{\theta} = 2\bar{X}$$

- Além disso, temos que  $\mathcal{E}(\hat{\theta}) = 2\frac{\theta}{2} = \theta$  (não viciado) e  $\mathcal{V}(\hat{\theta}) = \frac{4\theta^2}{12n^2} = \frac{\theta^2}{3n^2}$  ( $\mathcal{V}(\hat{\theta}) \xrightarrow{n \rightarrow \infty} 0$ ).

## Exemplo 4: $U(-\theta, \theta)$

- Seja  $X_1, \dots, X_n$  uma aa de  $X \sim U(-\theta, \theta)$ ,  $\theta \in \mathfrak{R}^+$
- Neste caso, note que  $\mathcal{E}(X) = 0$ , portanto, esta não é útil para obter o EMM de  $\theta$ . Por outro lado,  $\mathcal{E}(X^2) = \frac{\theta^2}{3}$ . Assim, temos que:

$$\mathcal{E}(X^2) = \frac{1}{n} \sum_{i=1}^n X_i^2 \rightarrow \frac{\hat{\theta}^2}{3} = \frac{1}{n} \sum_{i=1}^n X_i^2 \rightarrow \hat{\theta} = \sqrt{\frac{3}{n} \sum_{i=1}^n X_i^2} = \sqrt{3\bar{X}_2}$$

- Nesse caso, os cálculos de  $\mathcal{E}(\hat{\theta})$  e  $\mathcal{V}(\hat{\theta})$  são complicados.
- Exercício: obter os EMM para  $\theta$  no caso em que  $X \sim \text{Poisson}(\theta)$  e para  $\theta = (a, b)'$ , no caso em que  $X \sim \text{gama}(a, b)$ . Calcule, se viável, as distribuições exatas, bem como  $\mathcal{E}(\cdot)$ ,  $\mathcal{V}(\cdot)$ ,  $\mathcal{B}(\cdot)$  e  $\mathcal{EQM}(\cdot)$ .

# Métodos dos momentos

- Resultado assintótico: Seja  $h(\boldsymbol{\theta}) = (h_1(\boldsymbol{\theta}), \dots, h_k(\boldsymbol{\theta}))'$ ,  $h_r(\boldsymbol{\theta}) = \mathcal{E}(X^r)$ ,  $r = 1, 2, \dots, k$  e suponhamos que

$$\mathbf{H}(\boldsymbol{\theta}) = \begin{bmatrix} \frac{\partial h_1(\boldsymbol{\theta})}{\partial \theta_1} & \frac{\partial h_1(\boldsymbol{\theta})}{\partial \theta_2} & \cdots & \frac{\partial h_1(\boldsymbol{\theta})}{\partial \theta_k} \\ \frac{\partial h_2(\boldsymbol{\theta})}{\partial \theta_1} & \frac{\partial h_2(\boldsymbol{\theta})}{\partial \theta_2} & \cdots & \frac{\partial h_2(\boldsymbol{\theta})}{\partial \theta_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial h_k(\boldsymbol{\theta})}{\partial \theta_1} & \frac{\partial h_k(\boldsymbol{\theta})}{\partial \theta_2} & \cdots & \frac{\partial h_k(\boldsymbol{\theta})}{\partial \theta_k} \end{bmatrix}$$

seja de posto completo e que  $\frac{\partial}{\partial \theta_i} h_j(\boldsymbol{\theta})$ ,  $i, j = 1, 2, \dots, k$  seja contínua em  $\boldsymbol{\theta}$ .

# Métodos dos momentos

- Então,

$$\sqrt{n} \left( \hat{\boldsymbol{\theta}} - \boldsymbol{\theta} \right) \xrightarrow[n \rightarrow \infty]{D} N_k \left( \mathbf{0}, [\mathbf{H}^{-1}(\boldsymbol{\theta})]' \boldsymbol{\Sigma} [\mathbf{H}^{-1}(\boldsymbol{\theta})] \right).$$

- Em que  $\boldsymbol{\Sigma}_{i,j} = [\mu_{i+j} - \mu_i \mu_j]$ , em que  $\mu_i = \mathcal{E}(X^i), \forall i$ . Demonstração: [aqui](#).


## Exemplo de comparação de estimadores

- Seja  $X_1, \dots, X_n \stackrel{iid}{\sim} N(\mu, \sigma^2)$ ,  $\theta = (\mu, \sigma^2)'$ . Considere o interesse em estimar  $\sigma^2$ , através de um dos dois seguintes estimadores:  
$$\hat{\sigma}_1^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \text{ e } \hat{\sigma}_2^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$
- Note que  $\hat{\sigma}_1^2 = \frac{n-1}{n} \hat{\sigma}_2^2$ . Assim,  
$$\lim_{n \rightarrow \infty} \frac{\hat{\sigma}_1^2}{\hat{\sigma}_2^2} = \lim_{n \rightarrow \infty} \frac{n-1}{n} = 1 \text{ (assintoticamente equivalentes).}$$
- Sabemos que  $\frac{n-1}{\sigma^2} \hat{\sigma}_2^2 \sim \chi_{(n-1)}^2$ .

## Exemplo de comparação de estimadores

- Logo,  $\mathcal{E}(\hat{\sigma}_1^2) = \frac{n-1}{n}\sigma^2$  e  $\mathcal{E}(\hat{\sigma}_2^2) = \sigma^2$ .
- Por outro lado,  $\mathcal{B}(\hat{\sigma}_1^2) = -\frac{1}{n}\sigma^2$  e  $\mathcal{B}(\hat{\sigma}_2^2) = 0$ .
- Além disso,  $\mathcal{V}(\hat{\sigma}_1^2) = (n-1)\frac{2(\sigma^2)^2}{n^2}$  e  $\mathcal{V}(\hat{\sigma}_2^2) = \frac{2(\sigma^2)^2}{n-1}$ .
- Também,  $\mathcal{EQM}(\hat{\sigma}_1^2) = \frac{2n-1}{n^2}(\sigma^2)^2$  e  $\mathcal{EQM}(\hat{\sigma}_2^2) = \mathcal{V}(\hat{\sigma}_2^2) = \frac{2(\sigma^2)^2}{n-1}$ .
- Portanto, note que  $\frac{\mathcal{EQM}(\hat{\sigma}_1^2)}{\mathcal{EQM}(\hat{\sigma}_2^2)} = \frac{(2n-1)(n-1)}{2n^2} < 1 \rightarrow n > 1/3$ .

# Comparação dos EQM's



# Método de máxima verossimilhança

- Vimos anteriormente que, para uma aa de tamanho  $n$  de  $X$ , de sorte que  $f_{\mathbf{X}}(\mathbf{x}; \theta) = \prod_{i=1}^n f_X(x_i; \theta)$ , a verossimilhança associada a  $\theta \in \Theta$  é dada por

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


- A verossimilhança nos fornece, então, a probabilidade de observar uma dada amostra em função do  $\theta$  de forma exata (caso discreto) ou de forma aproximada (caso contínuo). Em particular, a amostra que fora observada.
- Assim, se obtivermos, através de algum procedimento, o máximo da verossimilhança, em termos de  $\theta$ , obteremos o valor mais provável responsável pela geração de uma dada amostra.




# Métodos de máxima verossimilhança

- Exemplo (Bernoulli): Seja  $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$ . Considere duas situações:
  - 1  $n = 10$   $\mathbf{x} = (0, 0, 1, 0, 0, 1, 0, 0, 1, 0)'$ ,  $\Theta = \{0, 3; 0, 6\}$ .
  - 2  $n=100$  valores simulados de uma Bernoulli(0, 3),  $\Theta = (0, 1)$ .
- Exemplo (exponencial): Seja  $X_1, \dots, X_n \stackrel{iid}{\sim} \exp(\theta)$ ,  $\mathcal{E}(X) = \theta$ . Considere uma amostra com  $n=100$  valores simulados de uma  $\exp(10)$ .
- Nos três slides a seguir, mostraremos as respectivas verossimilhanças.


# Exemplo 1 (Bernoulli)



## Exemplo 2 (Bernoulli)



# Exemplo exponencial



# Método de máxima verossimilhança

- Significado(s) da verossimilhança:
  - Caso discreto:

$$f_{\mathbf{X}}(\mathbf{x}; \theta) = P_{\theta}(\mathbf{X} = \mathbf{x}) = P_{\theta}(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n).$$

- Caso contínuo:

$$f_{\mathbf{X}}(\mathbf{x}; \theta) = \lim_{\Delta \rightarrow 0} P_{\theta}(x_1 - \Delta \leq X_1 \leq x_1 + \Delta, \dots, x_n - \Delta \leq X_n \leq x_n + \Delta).$$

# Método de máxima verossimilhança

- Def: Estimador de máxima verossimilhança (EMV) - Seja  $X_1, \dots, X_n$  va's (não necessariamente iid),  $f_{\mathbf{X}}(\cdot; \boldsymbol{\theta})$ ,  $\boldsymbol{\theta} \in \Theta \subseteq \mathcal{R}^k$ , é a fdp conjunta de  $\mathbf{X}$ . Qualquer valor  $\tilde{\boldsymbol{\theta}} = \tilde{\boldsymbol{\theta}}(\mathbf{x})$ , tal que:

$$L(\tilde{\boldsymbol{\theta}}) = \sup_{\boldsymbol{\theta} \in \Theta} L(\boldsymbol{\theta}),$$

é chamado de estimador de máxima verossimilhança de  $\boldsymbol{\theta}$  (pode haver somente um, mais de um, infinitos ou nenhum).

- Assim, a respectiva quantidade  $\hat{\boldsymbol{\theta}} \equiv \hat{\boldsymbol{\theta}}(\mathbf{X})$  é o (um) estimador de máxima verossimilhança de  $\boldsymbol{\theta}$ .

# Método de máxima verossimilhança

- Note que,  $\forall \tilde{\theta}$  emv, temos que :
  - $L(\tilde{\theta}; \mathbf{x}) > L(\theta; \mathbf{x}), \forall \theta \in \Theta, \theta \neq \tilde{\theta}$ .
  - $L(\tilde{\theta}; \mathbf{x}) \geq L(\theta; \mathbf{x}), \forall \theta \in \Theta$ .
- Em geral  $\sup_{\theta \in \Theta} L(\theta) = \max_{\theta \in \Theta} L(\theta)$ .
- Muitas vezes, dispositivos usuais de maximização (solução de sistemas de equações lineares ou otimização numérica) podem/devem ser utilizados.

# Exemplo


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

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

- Como  $L(\theta)$  não é contínua em  $\theta$ , não é possível derivá-la para se obter seu máximo. Contudo, note que, graficamente (próximo slide):
- Podemos notar, então, que  $\frac{1}{y_n^n} > \frac{1}{\theta^n}$ ,  $\forall \theta \in [y_n, \infty)$ . Portanto,  $\hat{\theta} = Y_n$  é o estimador de máxima verossimilhança de  $\theta$ .



# Exemplo $U(0, \theta)$




# Métodos de máxima verossimilhança

- Exemplo 2: Seja  $X_1, \dots, X_n$  uma amostra de  $X \sim U(\theta - \alpha, \theta + \alpha)$ ,  $\alpha > 0$  (conhecido),  $\theta \in \mathcal{R}$ . Calcular o emv de  $\theta$ .
- Temos que:

$$L(\theta) = \frac{1}{(2\alpha)^n} \mathbb{1}_{(y_n - \alpha, y_1 + \alpha)}(\theta)$$

- No gráfico do slide seguinte, vemos que  $L(\tilde{\theta}) = \sup_{\theta \in \Theta} L(\theta)$ ,  $\forall \tilde{\theta} \in (y_n - \alpha, y_1 + \alpha)$ ,  $\exists$  infinitas estimativas de máxima verossimilhança de  $\theta$ .
- Assim  $\hat{\theta}$ ,  $\forall Y_n - \alpha < \hat{\theta} < Y_1 - \alpha$ , será um EMV de  $\theta$ , particularmente  $\hat{\theta} = \frac{Y_1 + Y_n}{2}$ .

# Exemplo $U(\theta - \alpha, \theta + \alpha)$





# Comparação entre $\hat{\theta}_{MM}$ e $\hat{\theta}_{MV}$ no caso de $U(0, \theta)$

- Lembremos que  $\mathcal{E}(X) = \frac{\theta}{2}$  e  $\mathcal{V}(X) = \frac{\theta^2}{12}$ .
- $\hat{\theta}_{MM} = 2\bar{X}$  e  $\hat{\theta}_{MV} = Y_n = \max(\mathbf{X})$ .
- Distribuições:  $\hat{\theta}_{MM}$  (obter via fgm),  $f_{Y_n}(y; \theta) = \frac{ny^{n-1}}{\theta^n} \mathbb{1}_{(0, \theta)}(y)$ .
- Esperança:  $\mathcal{E}(\hat{\theta}_{MM}) = \theta$  e  $\mathcal{E}(\hat{\theta}_{MV}) = \frac{n}{n+1}\theta$ .
- Vício:  $\mathcal{B}(\hat{\theta}_{MM}) = 0$  e  $\mathcal{B}(\hat{\theta}_{MV}) = -\frac{\theta}{n+1}$ .
- Variância:  $\mathcal{V}(\hat{\theta}_{MM}) = \frac{\theta^2}{3n}$  e  $\mathcal{V}(\hat{\theta}_{MV}) = \frac{n\theta^2}{(n+1)^2(n+2)}$ .

## Comparação entre $\hat{\theta}_{MM}$ e $\hat{\theta}_{MV}$ no caso de $U(0, \theta)$

- EQM:  $\mathcal{E}QM(\hat{\theta}_{MM}) = \mathcal{V}(\hat{\theta}_{MM}) = \frac{\theta^2}{3n}$  e  
 $\mathcal{E}QM(\hat{\theta}_{MV}) = \mathcal{V}(\hat{\theta}_{MV}) + \mathcal{B}^2(\hat{\theta}_{MV}) = \frac{2\theta^2}{(n+2)(n+1)}$ .
- Assim  $\frac{\mathcal{E}QM(\hat{\theta}_{MM})}{\mathcal{E}QM(\hat{\theta}_{MV})} = \frac{(n+1)(n+2)}{6n} > 1 \Leftrightarrow n^2 - 3n + 2 > 0$  (raízes  $n_1 = 1$  e  $n_2 = 2$ ). Neste caso, a desigualdade será satisfeita sempre que  $n < 1$  ou  $n > 2$ . Ou seja,  $\hat{\theta}_{MV}$  é preferível a  $\hat{\theta}_{MM}$ , segundo o EQM.
- Note que podemos obter um estimador não viciado de  $\theta$  a partir de  $\hat{\theta}_{MV}$ , fazendo  $\hat{\theta} = \frac{n+1}{n}\hat{\theta}_{MV}$ .
- Assim,  $\mathcal{V}(\hat{\theta}) = \frac{(n+1)^2}{n^2} \frac{n\theta^2}{(n+1)^2(n+2)} = \frac{\theta^2}{n(n+2)}$ .
- Portanto  $\frac{\mathcal{V}(\hat{\theta})}{\mathcal{V}(\hat{\theta}_{MM})} = \frac{3}{n+2} < 1 \rightarrow n > 1$ . Assim, segundo a variância,  $\hat{\theta}$  também é preferível a  $\hat{\theta}_{MM}$ .

# Comparação de estimadores $U(0, \theta)$



# Resultado

- Seja  $\Theta \subseteq \mathcal{R}$  e  $L(\theta)$  duas vezes diferenciável, tal que

$$\left. \frac{\partial L(\theta)}{\partial \theta} \right|_{\theta=\tilde{\theta}} = 0; \quad \left. \frac{\partial^2 L(\theta)}{\partial \theta^2} \right|_{\theta=\tilde{\theta}} < 0$$

então  $\tilde{\theta}$  é a emv de  $\theta$  e, assim  $\hat{\theta}$  é o EMV de  $\theta$ .

- OBS:  $\tilde{\theta}$  maximiza  $L(\theta) \leftrightarrow \tilde{\theta}$  maximiza  $l(\theta) = \ln L(\theta) \leftrightarrow$ , pois  $\ln(\cdot)$  é uma função monótona e  $L(\theta) > 0 \forall \theta \in \Theta$  e  $\ln(L(\theta))$  é chamada de logverossimilhança.

## Exemplo

- Exemplo 3: Seja  $X_1, \dots, X_n$  uma aa de  $X$ ,  $X \sim \text{Bernoulli}(\theta)$ ,  $\theta \in [0, 1]$ . Temos que:

$$\begin{aligned}L(\theta) &= \theta^{n\bar{x}}(1-\theta)^{n(1-\bar{x})} \mathbb{1}_{\{0,1\}^n}(\mathbf{x}) \rightarrow \\ &\rightarrow l(\theta) = n\bar{x} \ln(\theta) + n(1-\bar{x}) \ln(1-\theta) + \text{const.}\end{aligned}$$

- Logo, a função escore ( $S(\theta)$ ) é dada por:

$$S(\theta) = \frac{dl(\theta)}{d\theta} = \frac{n\bar{x}}{\theta} - \frac{n(1-\bar{x})}{1-\theta}$$

$$\text{Assim, } S(\tilde{\theta}) = 0 \rightarrow (1-\tilde{\theta})\bar{x} = \tilde{\theta}(1-\bar{x}) \rightarrow \tilde{\theta} = \bar{x}$$



## Exemplo

- Por outro lado, a função Hessiana ( $H(\theta)$ ) é dada por

$$\begin{aligned}H(\theta) &= \frac{d^2 l(\theta)}{d\theta^2} = -\frac{n\bar{x}}{\theta^2} - \frac{n(1-\bar{x})}{(1-\theta)^2} \\ &= -n \left[ \frac{\bar{x}}{\theta^2} + \frac{1-\bar{x}}{(1-\theta)^2} \right]\end{aligned}$$

Logo,  $H(\tilde{\theta}) = -n \left[ \frac{1}{\tilde{\theta}} + \frac{1}{1-\tilde{\theta}} \right] < 0$ . Assim,  $\tilde{\theta}$  é a emv de  $\theta$  e, portanto,  $\hat{\theta}$  é o emv de  $\theta$ .

# Exemplo

- Note que  $\mathcal{E}(\hat{\theta}) = \theta$  e  $\mathcal{V}(\hat{\theta}) = \frac{\theta(1-\theta)}{n}$  (veja os slides) para ver algumas propriedades desse estimador.
- Contudo, a distribuição exata de  $\hat{\theta}$  é complicada de ser obtida.
- Exercício. Prove que, se a)  $x_i = 0, \forall i$  e b)  $x_i = 1, \forall i$  então, respectivamente,  $\hat{\theta}_{MV} = 0$  e  $\hat{\theta}_{MV} = 1$ .

# Resultado

- Suponha agora que  $\Theta \subset \mathcal{R}^k$  e que  $l(\theta)$  seja (duplamente: derivadas de primeira e segunda ordem) diferenciável com respeito à  $\theta$ . Seja  $\tilde{\theta}$  o **valor** de  $\theta$  que satisfaz:

$$\left\{ \begin{array}{l} \frac{\partial l(\theta)}{\partial \theta_1} = 0 \\ \frac{\partial l(\theta)}{\partial \theta_2} = 0 \\ \vdots \\ \frac{\partial l(\theta)}{\partial \theta_k} = 0 \end{array} \right. \quad (2)$$

então  $\tilde{\theta}$  é um candidato à emv de  $\theta$ .

# Resultado

- Se além da condição (5) ser satisfeita, tivermos ( $k=2$ ) que:

$$\left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_1^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} \right) \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_2^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} \right) - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_1 \partial \theta_2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} \right)^2 > 0$$

e

$$\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_1^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} < 0 \text{ ou } \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_2^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} < 0$$

então  $\tilde{\boldsymbol{\theta}}$  é a emv de  $\boldsymbol{\theta}$  e, conseqüentemente,  $\hat{\boldsymbol{\theta}}$  é o emv de  $\boldsymbol{\theta}$ .

# Resultado

- No caso geral ( $k \geq 2$ ), devemos ter que  $\mathbf{H}(\boldsymbol{\theta})$

$$\mathbf{H}(\boldsymbol{\theta}) = \begin{bmatrix} \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_1^2} & \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_1 \partial \theta_p} \\ \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_2 \partial \theta_1} & \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_2^2} & \cdots & \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_2 \partial \theta_p} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_p \partial \theta_1} & \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_p \partial \theta_2} & \cdots & \frac{\partial^2 l(\boldsymbol{\theta})}{\partial \theta_p^2} \end{bmatrix}$$

seja negativa definida (veja [aqui](#)).

- Neste caso ( $k \geq 2$ ) não, necessariamente, o ponto encontrado é de máximo.

## Exemplo

- Exemplo 4: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim N(\mu, \sigma^2)$ ,  $\theta = (\mu, \sigma^2)$  (desconhecido),  $\Theta = \mathcal{R} \times \mathcal{R}^2$ .
- Temos que

$$L(\theta) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\} \mathbb{1}_{\mathcal{R}^n}(\mathbf{x})$$
$$\rightarrow l(\theta) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2} \ln(\sigma^2) + \text{const}$$

- Assim, vem que o vetor escore é dado por  $\mathbf{S} = (S(\mu), S(\sigma^2))'$ , em que:

$$S(\mu) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu); \quad S(\sigma^2) = \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2\sigma^2}$$

## Exemplo

- Portanto, de  $\mathbf{S}(\tilde{\theta}) = \mathbf{0}$ , vem que

$$\begin{cases} \frac{1}{\tilde{\sigma}^2} \sum_{i=1}^n (x_i - \tilde{\mu}) = 0 \quad (*) \\ \frac{1}{2(\tilde{\sigma}^2)^2} \sum_{i=1}^n (x_i - \tilde{\mu})^2 = \frac{n}{2\tilde{\sigma}^2} \quad (**) \end{cases}$$

De (\*) temos que  $\tilde{\mu} = \bar{x}$  (\*\*\*) e, assim, de (\*\*\*) em (\*\*), vem que  $\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \tilde{\mu})^2$ .

- Por outro lado, temos que

$$\mathbf{H}(\theta) = \begin{bmatrix} H(\mu, \mu) & H(\mu, \sigma^2) \\ H(\sigma^2, \mu) & H(\sigma^2, \sigma^2) \end{bmatrix}$$

# Exemplo

- Cujos elementos são dados por:

$$H(\mu, \mu) = -\frac{n}{\sigma^2} ; H(\sigma^2, \sigma^2) = \frac{n}{2(\sigma^2)^2} - \frac{1}{(\sigma^2)^3} \sum_{i=1}^n (x_i - \mu)^2$$

$$H(\mu, \sigma^2) = H(\sigma^2, \mu) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)$$



# Exemplo

- Logo

$$H(\tilde{\mu}, \tilde{\mu}) = -\frac{n}{\tilde{\sigma}^2}$$

$$H(\tilde{\sigma}^2, \tilde{\sigma}^2) = \frac{n}{2(\tilde{\sigma}^2)^2} - \frac{1}{(\tilde{\sigma}^2)^3} \sum_{i=1}^n (x_i - \tilde{\mu})^2 = \frac{n}{2(\tilde{\sigma}^2)^2} - \frac{n}{(\tilde{\sigma}^2)^2} = -\frac{n}{2(\tilde{\sigma}^2)^2}$$

$$H(\tilde{\mu}, \tilde{\sigma}^2) = H(\tilde{\sigma}^2, \tilde{\mu}) = -\frac{1}{2\tilde{\sigma}^2} \sum_{i=1}^n (x_i - \tilde{\mu}) = 0$$

## Exemplo

- Por outro lado, temos que

$$H(\tilde{\mu}, \tilde{\mu})H(\tilde{\sigma}^2, \tilde{\sigma}^2) - [H(\tilde{\mu}, \tilde{\sigma}^2)]^2 = \frac{n^2}{2(\tilde{\sigma}^2)^3} > 0 \text{ e } H(\tilde{\mu}, \tilde{\mu}) = -\frac{n}{\tilde{\sigma}^2} < 0$$

- Portanto, conclui-se que  $\tilde{\mu}$  e  $\tilde{\sigma}^2$  são as emv de  $\theta$  e, assim  $\hat{\mu} = \bar{X}$  e  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  são os respectivos EMV.
- Exercício: obtenha os emv de  $\theta$ , baseado em uma aa de  $X$ , quando :
  - a)  $X \sim U(\alpha, \beta)$ ,  $\theta = (\alpha, \beta)'$
  - b)  $X \sim U(\alpha - \gamma, \alpha + \gamma)$ ,  $\theta = (\alpha, \gamma)'$   
considerando i)  $\alpha$  conhecido, ii)  $\gamma$  conhecido e iii) ambos desconhecidos

# Exemplo

- Exemplo 5: Seja  $X$  uma va com distribuição HG  $(N, n, a)$  (HG  $\equiv$  hipergeométrica) em que  $N$ : tamanho da população (muitas vezes o parâmetro de interesse),  $n$ : tamanho da amostra,  $a$ : número de elementos com a característica desejada, na população (também pode ser um parâmetro de interesse).
- Temos que ( $N$  será o parâmetro de interesse):

$$f_X(x; N) = \frac{\binom{a}{x} \binom{N-a}{n-x}}{\binom{N}{n}} \mathbb{1}_{\{c_1, \dots, c_2\}}(x)$$

em que  $c_1 = \max(0, n - N + a)$  e  $c_2 = \min(n, a)$ .

## Exemplo

- Defina  $r(N) = \frac{L(N)}{L(N-1)}$ , logo

$$r(N) = \frac{\frac{\binom{a}{x} \binom{N-a}{n-x}}{\binom{N}{n}}}{\frac{\binom{a}{x} \binom{N-1-a}{n-x}}{\binom{N-1}{n}}} = \frac{(N-a)(N-n)}{N(N-a-n+x)}$$

- Note, então, que

$$\begin{aligned} r(N) > 1 &\Leftrightarrow (N-a)(N-n) > N(N-a-n+x) \Leftrightarrow \\ N^2 - Nn - Na - an &> N^2 - Na - Nn + Nx \rightarrow N > \frac{an}{x} \end{aligned}$$

Analogamente, se  $r(N) < 1 \rightarrow N < \frac{an}{x}$ .

# Exemplo

- Então, a emv de  $N$  será, aproximadamente  $\frac{an}{x}$ , ou seja  $\tilde{N} \approx \frac{an}{x}$ .
- Se  $\frac{an}{x}$  não for inteiro, podemos considerar  $\lceil \frac{an}{x} \rceil$  e  $\lfloor \frac{an}{x} \rfloor$  e avaliar onde a verossimilhança é maior.
- Consequentemente, o emv de  $N$  será  $\hat{N} = \frac{an}{X}$ .

# Exemplo

- Exemplo 6: Seja  $X_1, \dots, X_n$  uma aa de  $X$ ,  $X \sim \text{gama}(r, \lambda)$ ,  $\mathcal{E}(X) = r\lambda$ ,  $\boldsymbol{\theta} = (r, \lambda)'$ ,  $\Theta = \mathcal{R}^+ \times \mathcal{R}^+$ .
- Temos que

$$L(\boldsymbol{\theta}) = \frac{1}{\lambda^{nr}(\Gamma(r))^n} e^{-\frac{n}{\lambda}\bar{x}} \prod_{i=1}^n x_i^{r-1} \mathbb{1}_{(\mathcal{R}^+)^n}(\mathbf{x})$$
$$\rightarrow l(\boldsymbol{\theta}) = -\frac{1}{\lambda} n\bar{x} + (r-1) \sum_{i=1}^n \ln(x_i) - nr \ln(\lambda) - n \ln(\Gamma(r))$$

## Exemplo

- Portanto, as componentes do vetor escore, são dadas por (função digama  $\Psi(r) = \frac{\Gamma'(r)}{\Gamma(r)}$ )

$$S(r) = \sum_{i=1}^n \ln(x_i) - n \ln(\lambda) - n\Psi(r) ; S(\lambda) = \frac{n\bar{x}}{\lambda^2} - \frac{nr}{\lambda}$$

- Dessa forma,

$$\begin{cases} \sum_{i=1}^n \ln(x_i) - n \ln(\tilde{\lambda}) - n\Psi(\tilde{r}) = 0 \\ \frac{n\bar{x}}{\tilde{\lambda}^2} - \frac{n\tilde{r}}{\tilde{\lambda}} = 0 \end{cases}$$

$\rightarrow \begin{cases} n \ln(\tilde{\lambda}) + n\Psi(\tilde{r}) = \sum_{i=1}^n \ln(x_i) \quad (*) \\ \tilde{\lambda} = \frac{\tilde{x}}{\tilde{r}} \quad (**) \end{cases}$

# Exemplo

- De (\*\*) em (\*), temos que:

$$-n \ln(\tilde{r}) + n\Psi(\tilde{r}) = \sum_{i=1}^n \ln(x_i) - n \ln(\bar{x})$$

a qual não tem solução explícita e, assim, algum método numérico para resolução de equações (sistemas) não linear(es), tem de ser empregado, como: algoritmo de Newton-Raphson, Escore de Fisher, BFGS, Nelder-Mead, L-BFGS-B, gradiente conjugado, simulated annealing entre outros. Veja [aqui](#) e [aqui](#), por exemplo.



# Exemplo

- Neste caso, a determinação se as estimativa são de mv, deve ser feita por métodos numéricos (avaliando se a matriz Hessiana é negativa definida)
- Caso  $r$  seja conhecido, pode-se provar que  $\hat{\lambda} = \frac{\bar{X}}{r}$  é o emv de  $\lambda$  (exercício). Obtenha também  $\mathcal{E}(\hat{\lambda})$ ,  $\mathcal{V}(\hat{\lambda})$  bem como sua distribuição exata (compare como respectivo emm).

# Propriedade da invariância dos emv

- Seja  $\Theta \subseteq \mathcal{R}^k$  e  $\tau : \Theta \rightarrow \Lambda \subseteq \mathcal{R}^r$ , em que  $\tau(\theta) = (\tau_1(\theta), \dots, \tau_r(\theta))'$ ,  $r \leq k$ .
- Suponha que  $r = k = 1$  e  $\tau(\theta) = \eta$  uma transformação 1 a 1, temos que

$$L^*(\eta, \mathbf{x}) = L(\tau^{-1}(\eta), \mathbf{x}) = L(\theta, \mathbf{x}) = \prod_{i=1}^n f_X(x_i; \theta)$$

- Assim, podemos verificar que:

$$\sup_{\eta \in \Lambda} L^*(\eta, \mathbf{x}) = \sup_{\eta \in \Lambda} L(\tau^{-1}(\eta); \mathbf{x}) = \sup_{\theta \in \Theta} L(\theta; \mathbf{x})$$

- Portanto,  $\sup_{\eta \in \Lambda} L^*(\eta, \mathbf{x}) = L(\tilde{\eta}; \mathbf{x})$ ,  $\tilde{\eta} = \tau(\hat{\theta})$ .
- Logo,  $\hat{\eta} = \tau(\hat{\theta})$  é o emv de  $\eta$ .

# Teorema

- Princípio da invariância dos emv: seja  $\hat{\theta}$  o emv de  $\theta \in \Theta \subseteq \mathcal{R}^k$  e  $\tau : \Theta \rightarrow \Lambda \subseteq \mathcal{R}^r, r \leq k$  (não, necessariamente, uma função 1 a 1). Então  $\tau(\hat{\theta})$  é o emv de  $\tau(\theta)$ ,  $\tau(\theta) = (\tau_1(\theta), \dots, \tau_k(\theta))'$  e  $\tau(\hat{\theta}) = (\tau_1(\hat{\theta}), \dots, \tau_k(\hat{\theta}))'$ .
- Precisamos particionar o espaço paramétrico associado à  $\eta$ .
- Dem: Defina  $L^*(\eta) = \sup_{\theta: \tau(\theta)=\eta} L(\theta)$ ,  $\eta \in \Lambda$ , a verossimilhança de  $\eta$  induzida por  $\tau$ .
- Seja  $\Lambda = \tau(\Theta)$  e para cada  $\eta \in \Lambda$ , defina  $\Theta_\eta = \{\theta \in \Theta : \tau(\theta) = \eta\}$ .
- Dessa forma, temos que  $L^*(\eta) = \sup_{\theta \in \Theta_\eta} L(\theta)$ .

# Teorema

- Além disso

$$L(\tilde{\eta}) = \sup_{\eta \in \Lambda} L^*(\eta) = \sup_{\eta \in \Lambda} \sup_{\theta \in \Theta_{\eta}} L(\theta) = \sup_{\theta \in \Theta} L(\theta) = L(\tilde{\theta}) \quad (3)$$

- Entretanto, como  $\tilde{\theta}$  é a emv de  $\theta$ , vem que

$$L(\tilde{\theta}) = \sup_{\theta \in \Theta_{\tilde{\eta}}} L(\theta) = L(\tau(\tilde{\theta})) \quad (4)$$

em que  $\Theta_{\tilde{\eta}} = \{ \tilde{\theta} \in \Theta : \tau(\tilde{\theta}) = \tilde{\eta} \}$ .

- Assim, de (3) e (4) temos que  $L(\tilde{\eta}) = L(\tau(\tilde{\theta}))$  e, assim,  $\tau(\tilde{\theta})$  é a emv de  $\tau(\theta)$ .

# Exemplo

- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Bernoulli}(\theta)$  e  $\tau(\theta) = \theta(1 - \theta)$  (entra na variância exata de  $\hat{\theta}_{MV}$ ).
- Como  $\hat{\theta}_{MV} = \bar{X}$  então, pelo princípio da invariância  $\hat{\eta} = \bar{X}(1 - \bar{X})$ .
- Exemplo: Seja  $X_i \stackrel{iid}{\sim} N(\mu, \sigma^2)$  e defina  $\tau(\theta) = P_{\theta}(X \leq x_0)$ ,  $x_0$  conhecido. Obtenha o emv de  $\tau(\theta)$ .
- Temos que

$$\eta = P_{\theta}(X \leq x_0) = P_{\theta} \left( Z \leq \frac{x_0 - \mu}{\sigma} \right)$$

## Exemplo & Teorema

- Assim, como  $\hat{\mu} = \bar{X}$  e  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  são os emv de  $\theta$ , então  $\hat{\eta} = P_{\theta} \left( Z \leq \frac{x_0 - \hat{\mu}}{\hat{\sigma}} \right)$  e  $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$ .
- Teorema: Seja  $T = t(\mathbf{X})$  uma estatística suficiente para  $\theta$  e  $\hat{\theta}$  seu respectivo emv. Então  $\hat{\theta} = f(t(\mathbf{X}))$  (vale também para o caso vetorial e/ou multivariado). Dem: exercício (usar o critério da fatoração).

## Exemplo

- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X$ ,  $X \sim \exp(\theta)$ . Obtenha o emv de  $x_q$ , o  $q$ -ésimo de  $X$ .
- Sabemos que:

$$F(x_q) = q, q \in (0, 1),$$

mas,

$$1 - e^{-x_q/\theta} = q \rightarrow 1 - q = e^{-x_q/\theta} \rightarrow x_q = -\theta \ln(1 - q).$$

- Assim, como  $\hat{\theta} = \bar{X}$  é o emv de  $\theta$ , então  $\hat{x}_q = -\bar{X} \ln(1 - q)$  é o emv de  $x_q$ .

## Exemplo

- Seja  $X_1, \dots, X_n$  uma amostra de  $X \sim U(\theta - 1/2, \theta + 1/2)$ . Já provamos (págs. 33 e 34) que se  $Y_n - \frac{1}{2} < \hat{\theta} < Y_n + \frac{1}{2}$ ,  $\hat{\theta}$  é um emv de  $\theta$ .
- Pode-se provar que

$$\hat{\theta}_\gamma = Y_n - \frac{1}{2} + \gamma(1 + Y_1 - Y_n), \gamma \in (0, 1)$$

- Sabemos que  $(Y_1, Y_n)'$  é uma estatística suficiente para  $\theta$ .
- Contudo,  $\hat{\theta}_\gamma = Y_n - \frac{1}{2} + \cos^2(X_1)(1 + Y_1 - Y_n)$  é um emv de  $\theta$ , mas  $\hat{\theta}_\gamma \neq g(Y_1, Y_n)$  ( $\hat{\theta}_\gamma = g(Y_1, Y_n, X_1)$ ).



# Exemplo

- Isto ocorre, essencialmente, pelo fato de que o  $\hat{\theta}_{MV}$  não ser único.
- Exercício: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Pareto}(\alpha, \beta)$ , ou seja,

$$f_X(x; \theta) = \frac{\alpha \beta^\alpha}{x^{\alpha+1}} \mathbb{1}_{[\beta, \infty)}(x).$$

Encontre o emv de  $\theta = (\alpha, \beta)' \in \mathcal{R}^+ \times \mathcal{R}^+$  e deduza todas as propriedades (esperança, distribuição etc) de forma exata, possíveis.

# Método de mínimos quadrados (MMQ)

- Este é um dos métodos mais utilizados, quando não se quer fazer suposições acerca da distribuição dos dados (nem mesmo que pertença à família de localização-escala).
- Uma ampla apresentação pode ser encontrada [aqui](#).
- Considere o modelo  $Y_i = g_i(\boldsymbol{\theta}) + \xi_i$ ,  $i = 1, 2, \dots, n$ ,  $\boldsymbol{\theta} \in \Theta \subseteq \mathcal{R}^k$  (sua suposição não é necessária para se considerar o método de MQ).
- Admita que as funções  $g_i(\cdot)$  são conhecidas e que  $\xi_1, \dots, \xi_n$  são erros não aleatórios e não correlacionados, tais que:  $\mathcal{E}(\xi_i) = 0$  e  $\mathcal{V}(\xi_i) = \sigma^2$  (em geral, desconhecido).
- Além disso,  $g_i(\cdot)$  é diferenciável em  $\Theta$ ,  $\forall i$  (pelo menos duas vezes).

# Método de mínimos quadrados (MMQ)

- A (uma) estimativa de MQ de  $\theta$  é obtida minimizando-se (através de algum procedimento apropriado) a expressão:

$$Q(\theta) = \sum_{i=1}^n (y_i - g_i(\theta))^2$$

em relação à  $\theta$ . Portanto, se  $\tilde{\theta}$  é a eqm de  $\theta$ , então:

$$Q(\tilde{\theta}) = \sum_{i=1}^n (y_i - g_i(\tilde{\theta}))^2 = \inf_{\theta \in \Theta} \sum_{i=1}^n (y_i - g_i(\theta))^2.$$

- No caso unidimensional, devemos verificar se:

$$\left. \frac{\partial^2 Q(\theta)}{\partial \theta^2} \right|_{\theta=\tilde{\theta}} > 0$$

# Método de mínimos quadrados (MMQ)

- No caso bidimensional, devemos verificar se:

$$\left( \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_1^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} \right) \left( \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_2^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} \right) - \left( \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_1 \partial \theta_2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} \right)^2 > 0$$

e

$$\frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_1^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} > 0 \text{ ou } \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_2^2} \Big|_{\boldsymbol{\theta}=\tilde{\boldsymbol{\theta}}} > 0$$

# Método de mínimos quadrados (MMQ)

- No caso mais geral, devemos ter que  $H(\boldsymbol{\theta})$

$$H(\boldsymbol{\theta}) = \begin{bmatrix} \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_1^2} & \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_1 \theta_2} & \cdots & \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_1 \theta_p} \\ \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_2 \theta_1} & \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_2^2} & \cdots & \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_2 \theta_p} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_p \theta_1} & \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_p \theta_2} & \cdots & \frac{\partial^2 Q(\boldsymbol{\theta})}{\partial \theta_p^2} \end{bmatrix}$$

deve ser positiva definida. Não, necessariamente, temos garantias de que o ponto é de mínimo.

# Método de mínimos quadrados (MMQ)

- Podemos estimar  $\sigma^2$  através de  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - g_i(\hat{\theta}))^2$ .
- Exemplo 1: Seja  $Y_i = \theta + \xi_i$ ,  $i = 1, 2, \dots, n$ . Nest caso,  $g_i(\theta) = \theta$ ,  $\forall i$ ,  $\theta \in \Theta \subseteq \mathcal{R}$ . Assim  $h(\theta) = \sum_{i=1}^n (y_i - \theta)^2$
- Podemos provar que  $\hat{\theta} = \bar{Y}$  é o emq de  $\theta$  (exercício). Se, além disso,  $\xi \stackrel{iid}{\sim} N(0, \sigma^2)$ , então  $\hat{\theta} = \bar{Y}$  também é o emv de  $\theta$ .
- Exemplo 2: Seja  $Y_i = \alpha + \beta x_i + \xi_i$ ,  $i = 1, 2, \dots, n$ . Neste caso,  $g_i(\theta) = \alpha + \beta x_i$ ,  $\forall i$ ,  $\theta = (\alpha, \beta)' \in \Theta \subseteq \mathcal{R}^2$ .
- Pode-se provar que a função:  $h(\theta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$ , atinge o mínimo em  $\tilde{\theta} = (\tilde{\alpha}, \tilde{\beta})'$ , em que (exercício):

$$\tilde{\alpha} = \bar{y} - \tilde{\beta} \bar{x} \text{ e } \tilde{\beta} = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

# Método de mínimos quadrados (MMQ)

- Consequentemente  $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{x}$  e  $\hat{\beta} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(X_i - \bar{x})}{\sum_{i=1}^n (X_i - \bar{x})^2}$ , são os emq de  $\theta$ .
- Neste caso, se  $\xi_i \stackrel{iid}{\sim} N(0, \sigma^2)$ ,  $\hat{\theta} = (\hat{\alpha}, \hat{\beta})'$  também é o emv de  $\theta$  (exercício).
- Em situações mais gerais, pode-se utilizar outras funções de perda (distâncias) ( $g(\theta)$ ), função dos valores observados e esperados.

# Método de mínimos quadrados (MMQ)

- Nesses casos, a emq de  $\theta$  é obtido através da solução (das equações)

$$\sum_{i=1}^n d(y_i, \mathcal{E}(y_i; \tilde{\theta})) = \inf_{\theta \in \Theta} \sum_{i=1}^n d(y_i, \mathcal{E}(y_i; \theta)),$$

em que  $\mathcal{E}(Y_i; \theta) = \mathcal{E}_{\theta}(Y_i)$  e  $d(., .)$  é uma função de perda (distância) apropriada, por exemplo

$$d(y_i; \mathcal{E}(Y_i; \theta)) = |y_i - \mathcal{E}(Y_i; \theta)|.$$

- Veja o exemplo da regressão quantílica: [aqui](#).



# Multiplicadores de Lagrange

- As vezes, temos interesse em obter os estimadores de  $\theta$ , sob alguma restrição ou, isto é mais conveniente.
- Por exemplo, poderíamos estar interessados em obter o emv de  $\theta \in \Theta \subseteq \mathcal{R}^k$ , sujeito à  $g_i(\theta) = 0, \forall i = 1, 2, \dots, r, r \leq k$  (não guarda, necessariamente, relação com a função definida para o método de MQ)
- Neste caso particular, podemos utilizar o métodos dos multiplicadores de Lagrange, ou seja, teremos que maximizar

$$g(\theta, \lambda) = l(\theta) - \lambda'g(\theta) = l(\theta) - \sum_{i=1}^k \lambda_i g_i(\theta)$$

$$\lambda = (\lambda_1, \dots, \lambda_k)' \in \mathcal{R}^r.$$

# Multiplicadores de Lagrange

- Exemplo,  $\mathbf{X} \sim \text{multinomial}(n, \boldsymbol{\theta})$ ,  $n$  conhecido,  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)'$ ,  $\mathbf{X} = (X_1, \dots, X_k)'$ ,  $\sum_{i=1}^k x_i = n$  e  $\sum_{i=1}^k \theta_i = 1$ ,  $\theta_i \in (0, 1)$  e  $x_i \in \{0, 1, 2, \dots, n\}$ ,  $\forall i$ . Encontre o emv de  $\boldsymbol{\theta}$ . Temos que

$$\frac{n!}{\prod_{i=1}^k x_i!} \prod_{i=1}^k \theta_i^{x_i} \mathbb{1}_A(\mathbf{x})$$

em que  $A$  é o conjunto que considera as restrições

$\sum_{i=1}^k x_i = n$ ,  $x_i \in \{0, 1, 2, \dots, n\}$ , veja também: [aqui](#).

- Para obter o emv de  $\boldsymbol{\theta}$ , podemos maximizar

$$g(\boldsymbol{\theta}, \lambda) = l(\boldsymbol{\theta}) - \lambda \left( \sum_{i=1}^k \theta_i - 1 \right) = \sum_{i=1}^k x_i \ln(\theta_i) - \lambda \left( \sum_{i=1}^k \theta_i - 1 \right) + \text{const}$$

# Multiplicadores de Lagrange

- Assim,

$$S(\theta_i) = \frac{\partial g(\boldsymbol{\theta}, \lambda)}{\partial \theta_i} = \frac{x_i}{\theta_i} - \lambda, i = 1, 2, \dots, k$$

$$S(\lambda) = \sum_{i=1}^k \theta_i - 1$$

- O sistema associado às equações de verossimilhança é dado por:

$$\begin{cases} S(\tilde{\theta}_i) = 0, i = 1, 2, \dots, k \\ S(\tilde{\lambda}) = 0 \end{cases} \rightarrow \begin{cases} \frac{x_i}{\tilde{\theta}_i} - \tilde{\lambda} = 0, i = 1, 2, \dots, k(*) \\ \sum_{i=1}^k \tilde{\theta}_i - 1 = 0(**) \end{cases} \rightarrow$$

# Multiplicadores de Lagrange

- De (\*\*), temos que  $\sum_{i=1}^k \tilde{\theta}_i = 1$  (\*\*\*). Portanto, de (\*\*\*) em (\*), vem que

$$\sum_{i=1}^k x_i = \tilde{\lambda} \sum_{i=1}^k \tilde{\theta}_i \rightarrow \tilde{\lambda} = \frac{\sum_{i=1}^k x_i}{\sum_{i=1}^k \tilde{\theta}_i} = \frac{\sum_{i=1}^k x_i}{1} = \sum_{i=1}^k x_i = n$$

- Finalmente, de (\*\*\*\*) em cada equação de (\*), temos que  $\tilde{\theta}_i = \frac{x_i}{n}$  e, assim,  $\hat{\theta}_i = \frac{X_i}{n}$  (calcular esperança, variância e eqm de  $\hat{\theta}_i$ ).
- Exercício: provar que a matriz Hessiana  $H(\theta, \lambda)$  é negativa definida e, portanto  $\hat{\theta}_i$  é o emv de  $\theta_i$ ,  $i = 1, 2, \dots, K$ .
- Inferência Estatística restrita: [aqui](#).

# Método da substituição

- Seja  $\hat{\theta}$  algum estimador (emv, emm, emq) de  $\theta \in \Theta \subseteq \mathcal{R}^k$  e  $\tau(\theta) = (\tau_1(\theta), \dots, \tau_k(\theta))'$  funções de interesse. Então, um estimador, digamos  $\tau(\hat{\theta})$  para  $\tau(\theta)$ , é obtido através de

$$\tau(\hat{\theta}) = (\tau_1(\hat{\theta}), \dots, \tau_k(\hat{\theta}))'.$$

- Exemplo: Seja  $X_1, \dots, X_n \stackrel{iid}{\sim} U(0, \theta), \theta > 0$ . Então  $\hat{\theta} = 2\bar{X}$  é o emm de  $\theta$ . Seja  $\tau(\theta) = \mathcal{V}(X) = \frac{\theta^2}{12}$ .
- Logo um estimador para  $\tau(\theta)$  (que não será, necessariamente, o emm dele) é dado por  $\tau(\hat{\theta}) = \frac{\hat{\theta}^2}{12} = \frac{\bar{X}^2}{3}$ .

# Comparação de estimadores

- Já vimos como comparar estimadores, segundo alguns critérios como valor esperado, variância e EQM.
- Nesta parte aprofundaremos tal discussão.
- Suponha que queremos estimar  $\theta$ , associado à  $X \sim f_X(\cdot; \theta)$  com base em uma amostra aleatória  $X = (X_1, \dots, X_n)'$ .
- Como vimos, não é possível obtermos estimadores uniformemente ótimos ( $\forall \theta \in \Theta$  e  $\forall F_X(\cdot; \theta)$ ).
- Assim, para obtermos estimadores ótimos, deveremos nos restringir à classes específicas (sob certas restrições).

# Comparação de estimadores

- Pergunta:

- 1) Que propriedades um (bom) estimador deve ter?
- 2) Que critérios devemos utilizar para selecionarmos um estimador ótimo?

- Exemplo: Considere dois estimadores,  $\hat{\theta}_1$  e  $\hat{\theta}_2$ , de sorte que  $\hat{\theta}_1 \sim U(\theta - 1/2, \theta + 1/2)$  e  $\hat{\theta}_2 \sim U(\theta - 1, \theta + 1)$ . Assim

$$\begin{aligned}\mathcal{E}(\hat{\theta}_1) &= \theta & ; & & \mathcal{E}(\hat{\theta}_2) &= \theta \\ \mathcal{V}(\hat{\theta}_1) &= \frac{1}{12} & ; & & \mathcal{V}(\hat{\theta}_2) &= \frac{1}{3}\end{aligned}$$

- Nesse caso  $\hat{\theta}_1$  seria preferível à  $\hat{\theta}_2$ , se utilizarmos a variância como critério de escolha (dado que os valores esperados são iguais).
- Em geral, busca-se  $\mathcal{E}(\hat{\theta}) \cong \theta$  (aproximadamente ou igual) e  $\mathcal{V}(\hat{\theta}) \approx 0$  (pequena).

# Comparação de estimadores

- Def: Um estimador  $\hat{\theta}$  de  $\theta$  (ou de  $\tau(\theta)$ ) é dito ser não viciado (ou não viesado ou não tendencioso) se:

$$\mathcal{E}_{\theta}(\hat{\theta}) = \theta \quad [\mathcal{E}_{\theta}(\hat{\theta}) = \tau(\theta)], \forall \theta \in \Theta \subseteq \mathcal{R}$$

- Exemplo 1: Seja  $X_i \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$ , então  $\hat{\theta} = \bar{X}$  é um estimador não viciado de  $\theta$ .
- Exemplo 2: Seja  $X_i \stackrel{iid}{\sim} N(\mu, \sigma^2)$ . Nesse caso,  $\hat{\theta} = (\bar{X}, \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2)'$  é viciado para  $\theta$  pois, apesar de  $\bar{X}$  ser não viciado para  $\mu$ ,  $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  é viciado para  $\sigma^2$ .



## Comparação de estimadores

- Exemplo 3: Seja  $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Poisson}(\theta)$ ,  $\theta > 0$ . Seja  $\hat{\tau}(\theta) = (-2)^{X_1}$  um estimador para  $\tau(\theta) = e^{-3\theta}$ . Note que

$$\mathcal{E}_\theta(\hat{\tau}(\theta)) = \sum_{x=0}^{\infty} (-2)^x \frac{e^{-\theta} \theta^x}{x!} = e^{-\theta} \sum_{x=0}^{\infty} \frac{(-2\theta)^x}{x!} = e^{-3\theta} = \tau(\theta)$$

Contudo, apesar de  $\hat{\tau}(\theta)$  ser não viciado, note que  $P(\hat{\tau}(\theta) < 0) > 0$ . Assim, tal estimador poderia não ser apropriado.

- Exemplo 4: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Bernoulli}(\theta)$ ,  $\theta \in (0, 1)$  e  $\tau(\theta) = \frac{\theta}{1-\theta}$ . Neste caso,  $\nexists$  env (estimador não viciado) de  $\tau(\theta)$ . Suponha, então, que  $\exists$  tal estimador, então (lembrando que temos um total de  $2^n$  amostras possíveis), temos que (slide seguinte):

# Comparação de estimadores

## ■ Assim

$$\begin{aligned}\mathcal{E}_\theta(\hat{\theta}) &= \sum_{\mathbf{x}} \tilde{\theta}(\mathbf{x}) \theta^{n\bar{x}} (1-\theta)^{n(1-\bar{x})} = \frac{\theta}{1-\theta} \\ &\rightarrow \sum_{j=1}^{2^n} \tilde{\theta}_j \theta^{k_j} (1-\theta)^{n-k_j} = \frac{\theta}{1-\theta} \\ &\rightarrow \sum_{j=1}^{2^n} \tilde{\theta}_j \theta^{k_j-1} (1-\theta)^{n-k_j} = (1-\theta)^{-1}, \forall \theta \in \Theta\end{aligned}$$

O que é uma contradição pois está-se afirmando que um polinômio de grau  $n$  (em função de  $\theta$ ) é igual à  $(1-\theta)^{-1}$ . Assim, não existe um env para  $\frac{\theta}{1-\theta}$ , neste caso.

# Comparação de estimadores

- Erro-quadrático médio (já fora definido). De uma forma geral, temos que  $\mathcal{EQM}_\theta(\theta) = \mathcal{E}_\theta[(\hat{\theta} - \theta)^2]$ .
- Note que

$$\begin{aligned}\mathcal{E}_\theta[(\hat{\theta} - \theta)^2] &= \mathcal{E}_\theta[(\hat{\theta} - \mathcal{E}(\hat{\theta}) - (\theta - \mathcal{E}(\hat{\theta})))^2] \\ &= \mathcal{E}_\theta[(\hat{\theta} - \mathcal{E}(\hat{\theta}))^2] + \mathcal{E}_\theta[(\theta - \mathcal{E}(\hat{\theta}))^2] \\ &\quad - 2\mathcal{E}_\theta[(\hat{\theta} - \mathcal{E}(\hat{\theta}))(\theta - \mathcal{E}(\hat{\theta}))] \\ &= \mathcal{V}_\theta(\hat{\theta}) + \mathcal{B}^2(\hat{\theta}) - 2(\theta - \mathcal{E}(\hat{\theta}))\mathcal{E}_\theta[(\hat{\theta} - \mathcal{E}(\hat{\theta}))] \\ &= \mathcal{V}_\theta(\hat{\theta}) + \mathcal{B}^2(\hat{\theta})\end{aligned}$$

A quantidade  $\mathcal{B}_\theta(\hat{\theta})$  é chamada de vício do estimador, em que se  $\mathcal{B}_\theta(\hat{\theta}) = 0 \rightarrow \mathcal{V}(\hat{\theta}) = \mathcal{EQM}(\hat{\theta})$ .

# Exemplo

- Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Bernoulli}(\theta)$ ,  $\theta \in (0, 1)$
- Sejam  $\hat{\theta}_1$  e  $\hat{\theta}_2$ , dois estimadores para  $\theta$ , tais que  $\hat{\theta}_1 = \bar{X}$  e  $\hat{\theta}_2 = \frac{\alpha + n\bar{X}}{\alpha + \beta + n}$ ,  $\alpha, \beta \in \mathcal{R}^+$ .
- Pode-se provar (para  $\hat{\theta}_1$  já fora provado) que:

$$\mathcal{E}_\theta(\hat{\theta}_1) = \theta \quad ; \quad \mathcal{E}_\theta(\hat{\theta}_2) = \frac{\alpha + n\theta}{\alpha + \beta + n}$$

$$\mathcal{B}_\theta(\hat{\theta}_1) = 0 \quad ; \quad \mathcal{B}_\theta(\hat{\theta}_2) = \frac{\alpha + n\theta}{\alpha + \beta + n} - \theta$$





$$\mathcal{V}_\theta(\hat{\theta}_1) = \frac{\theta(1-\theta)}{n} \quad ; \quad \mathcal{V}_\theta(\hat{\theta}_2) = \frac{n\theta(1-\theta)}{(\alpha + \beta + n)^2}$$

$$\mathcal{EQM}(\hat{\theta}_1) = \frac{\theta(1-\theta)}{n} \quad ; \quad \mathcal{EQM}(\hat{\theta}_2) = \frac{n\theta(1-\theta)}{(\alpha + \beta + n)^2} + \left[ \frac{\alpha + n\theta}{\alpha + \beta + n} - \theta \right]^2$$

# Exemplo

- Tomando  $\alpha = \beta = \frac{\sqrt{n}}{2}$ , temos que  $\mathcal{EQM}(\hat{\theta}_2) = \frac{n}{4(\sqrt{n}+n)^2}$ .
- Graficamente (slides seguinte): linha sólida em negrito -  $\hat{\theta}_1$ ; linha sólida em negrito -  $\hat{\theta}_2$ .
- Exercício: obter os pontos  $\{a_n, b_n\}$ , em relação à  $\theta$ , tais que  $\mathcal{EQM}(\hat{\theta}_1) = \mathcal{EQM}(\hat{\theta}_2)$  ( $\alpha = \beta = \frac{\sqrt{n}}{2}$ ).
- Assim, em termos do  $\mathcal{EQM}$ , temos que o  $\hat{\theta}_1$  é melhor que  $\hat{\theta}_2$  para  $\theta \in (0, a_n) \cup (b_n, 1)$

# Comparação dos EQM em função de $\theta$ e $n$



# Definições

- Se  $\hat{\theta}_1$  e  $\hat{\theta}_2$  são dois estimadores de  $\theta$ , dizemos que  $\hat{\theta}_1$  é melhor do que  $\hat{\theta}_2$ , em termos do EQM se

$$\mathcal{EQM}(\hat{\theta}_1) \leq \mathcal{EQM}(\hat{\theta}_2), \forall \theta \in \Theta.$$

- Se ambos forem não viciados, isso equivale a dizer que  $\hat{\theta}_1$  é melhor do que  $\hat{\theta}_2$ , em termos da variância, ou seja

$$\mathcal{V}(\hat{\theta}_1) \leq \mathcal{V}(\hat{\theta}_2), \forall \theta \in \Theta.$$

- Embora não seja a forma mais apropriada, também podemos comparar os estimadores através das variâncias mesmo se pelo menos um deles for não viciado.

# Estimadores ótimos

- Seja  $C_\tau = \left\{ \hat{\theta} : \mathcal{E}(\hat{\theta}) = \tau(\theta), \forall \theta \in \Theta \right\}$  a classe dos estimadores não viesados de  $\tau(\theta)$  e vamos supor que  $C_\tau \neq \emptyset$ . Nosso objetivo é encontrar  $\hat{\theta}^*$  em  $C_\tau$ ,

$$\mathcal{V}(\hat{\theta}^*) \leq \mathcal{V}(\hat{\theta}), \forall \theta \in \Theta, \forall \hat{\theta}^* \neq \hat{\theta} \quad (5)$$

- Definição: um estimador pertencente à  $C_\tau$  que satisfaz a (5) é dito ser um estimador não viesado de variância uniformemente mínima (ENVVUM).
- Na busca por esse tipo de estimador, os conceitos de redução de dados ser-nos-ão bem úteis.



# Condições de regularidade

- Seja  $\mathbf{X} = (X_1, \dots, X_n)'$  uma aa de  $X \sim f_{\mathbf{X}}(\cdot; \theta)$ ,  $\theta \in \Theta \subseteq \mathcal{R}$ . As condições de regularidade são:

- $I(\theta) < \infty, \forall \theta \in \Theta$ , em que  $I(\theta) = \mathcal{E} \left[ \left( \frac{\partial}{\partial \theta} \ln f(\mathbf{X}; \theta) \right)^2 \right]$  (Informação de Fisher)
- $\forall T = t(\mathbf{X}), \mathcal{E} [|t(\mathbf{X})|] < +\infty$ , então

$$\frac{\partial}{\partial \theta} \int_{\mathcal{R}^n} t(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \text{ e } \int_{\mathcal{R}^n} \frac{\partial}{\partial \theta} t(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x}$$

$\exists$  e são contínuas em  $\theta$

3)

$$\frac{\partial}{\partial \theta} \int_{\mathcal{R}^n} t(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} = \int_{\mathcal{R}^n} \frac{\partial}{\partial \theta} t(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x}$$

# Teorema de Cramer-Rao

- Seja  $\mathbf{X} = (X_1, \dots, X_n)'$  uma aa de  $f_X(\cdot; \theta)$ ,  $\theta \in \Theta$  e  $T = t(\mathbf{X})$  um estimador não viciado de  $\tau(\theta)$ ,  $\tau : \Theta \rightarrow \mathcal{R}$  é uma função diferenciável. Se as condições de regularidade forem satisfeitas então:

$$\mathcal{V}(T) \geq \frac{\left[\frac{d}{d\theta}\tau(\theta)\right]^2}{I(\theta)}, \forall \theta \in \Theta \quad (6)$$

- Obs: As distribuições pertencentes à FE satisfazem as CR (denote:  $\frac{d}{d\theta}\tau(\theta) = \tau'(\theta)$ ).
- A inequação (6) é conhecida como limite inferior de Cramer-Rao (LICR).
- Assim, todo e qualquer estimador não viciado cuja variância atingir o LICR será um ENVVUM.

# Teorema de Cramer-Rao

- Demonstração: Sejam  $Y$  e  $W$  va's,  $\mathcal{E}(Y) = 0$ . Assim

$$\text{Cov}^2(Y, W) \leq \mathcal{V}(Y)\mathcal{V}(W) = \mathcal{E}(Y^2)\mathcal{V}(W)$$

- Portanto,

$$\text{Cov}^2\left(t(\mathbf{X}), \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta)\right) \leq \mathcal{V}(t(\mathbf{X}))\mathcal{E}\left[\left(\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta)\right)^2\right] \quad (7)$$

# Teorema de Cramer-Rao

- Mas

$$\begin{aligned}\text{Cov}\left(t(\mathbf{X}), \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta)\right) &= \int_{\mathcal{R}^n} t(\mathbf{x}) \left(\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta)\right) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \\ &= \int_{\mathcal{R}^n} t(\mathbf{x}) \frac{\frac{\partial}{\partial \theta} f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{x}; \theta)} f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \\ &= \frac{\partial}{\partial \theta} \int_{\mathcal{R}^n} t(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} = \frac{\partial}{\partial \theta} \mathcal{E}(t(\mathbf{X})) \\ &= \tau'(\theta)\end{aligned}\quad (8)$$

- Logo, de (8) em (7) vem que

$$\mathcal{V}(T) \geq \frac{\left[\frac{d}{d\theta} \tau(\theta)\right]^2}{I(\theta)}, \forall \theta \in \Theta$$

# Teorema de Cramer-Rao

- Exercício. Prove, sob as condições de regularidade, que:

$$\mathcal{E} \left\{ \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right\} = 0; \text{ e } I(\theta) = \mathcal{E} \left\{ -\frac{\partial^2}{\partial \theta^2} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right\}$$

- OBS: Se  $X_1, \dots, X_n$  é uma aa de  $f_{\mathbf{X}}(\cdot; \theta)$  então  $I(\theta)$  (associada a  $f_{\mathbf{X}}(\cdot; \theta)$ ) é tal que:  $I(\theta) = nI_1(\theta)$ , em que

$$I_1(\theta) = \mathcal{E} \left\{ -\frac{\partial^2}{\partial \theta^2} \ln f_X(X; \theta) \right\}$$

# Teorema de Cramer-Rao

- Corolário: Sob as condições do teorema,

$$\mathcal{V}_\theta(T) = \frac{\left[\frac{d}{d\theta}\tau(\theta)\right]^2}{I(\theta)} \leftrightarrow \exists a(\theta), a(\theta)[t(\mathbf{x}) - \tau(\theta)] = \frac{\partial}{\partial\theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta), \forall \theta \in \Theta$$

- Prova: Note que

$$\text{Cov}\left(T, \frac{\partial}{\partial\theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta)\right) = \text{Cov}\left(T - \tau(\theta), \frac{\partial}{\partial\theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta)\right)$$

# Teorema de Cramer-Rao

- A igualdade (no LICR) ocorre se, e somente se,

$$\text{Cov}(Y, W) = E(Y^2)\mathcal{V}(W) \leftrightarrow \text{Corre}(Y, W) = 1,$$

ou seja se  $Y = aW + b$ , para algum vetor  $(a,b)$  (não aleatório). Ou seja, se e somente se,  $\exists$  constantes  $a^*(\theta)$  e  $b^*(\theta)$

$$T - \tau(\theta) = a^*(\theta) \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) + b^*(\theta)$$

- Cont. ou seja, se:

$$\frac{T - \tau(\theta)}{a^*(\theta)} = \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) + \frac{b^*(\theta)}{a^*(\theta)}$$

- Assim, se  $a^*(\theta) = a(\theta)^{-1}$  e  $b^*(\theta) = 0$ , o  $LICR(\tau(\theta))$  é atingido.

# LICR

- Exemplo 1: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \exp(\theta)$ ,  $\mathcal{E}(X) = \theta$ . Encontre o  $LICR(\theta)$ .
- Temos que:

$$H(\theta) = \frac{\partial^2}{\partial \theta^2} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) = \frac{n}{\theta^2} - \frac{2n\bar{X}}{\theta^3}$$
$$I(\theta) = \mathcal{E}(-H(\theta)) = \frac{-n}{\theta^2} + \frac{2n}{\theta^2} = \frac{n}{\theta^2}$$

- Então o  $LICR(\theta) = \frac{\theta^2}{n}$ .
- Por outro lado, sabemos que  $\hat{\theta}_{MV} = \bar{X}$ , de sorte que,  $\mathcal{E}(\hat{\theta}_{MV}) = \theta$  e  $\mathcal{V}(\hat{\theta}_{MV}) = \frac{\theta^2}{n}$ . Assim, neste caso,  $\hat{\theta}_{MV}$  é um ENVVUM para  $\theta$ .



# LICR

- Exemplo 1.1: Vamos agora encontrar o  $LICR(\theta) = \frac{1}{\theta}$ . Temos que  $LICR(\tau(\theta)) = \frac{[\tau'(\theta)]^2}{I(\theta)} = \frac{1}{n\theta^2}$ .
- Vamos estudar o comportamento do estimador  $\hat{\theta} = \frac{1}{\bar{X}} = \frac{n}{S}$ ,  $S = \sum_{i=1}^n X_i$ . Note que  $S \sim \text{gama}(n, \theta)$ . Assim:

$$\begin{aligned}\mathcal{E}(\hat{\theta}^r) &= \int_0^{\infty} \frac{1}{\theta^n \Gamma(n)} \frac{n^r}{s^r} e^{-s/\theta} s^{n-1} ds \\ &= \frac{n^r}{\theta^n \Gamma(n)} \theta^{n-r} \Gamma(n-r) \underbrace{\int_0^{\infty} \frac{1}{\theta^{n-r} \Gamma(n-r)} e^{-s/\theta} s^{n-r-1} ds}_1 \\ &= \frac{n^r}{\theta^r} \frac{\Gamma(n-r)}{\Gamma(n)}\end{aligned}$$

- Assim,  $\mathcal{E}(\hat{\theta}) = \frac{n}{\theta} \frac{1}{n-1} \rightarrow \mathcal{E}\left(\frac{n-1}{n}\hat{\theta}\right) = \frac{1}{\theta} \rightarrow \mathcal{E}(\hat{\theta}^*) = \frac{1}{\theta}$ ,  $\hat{\theta}^* = \frac{n-1}{n}\hat{\theta}$
- Além disso,  $\mathcal{V}(\hat{\theta}^2) = \frac{n^2}{\theta^2(n-1)(n-2)}$ . Assim,

$$\mathcal{V}(\hat{\theta}) = \frac{n^2}{\theta^2(n-1)(n-2)} - \frac{n^2}{\theta^2(n-1)^2} = \frac{n^2}{\theta^2(n-1)^2(n-2)}$$

- Portanto,  $\mathcal{V}(\hat{\theta}^*) = \frac{(n-1)^2}{n^2} \mathcal{V}(\hat{\theta}) = \frac{1}{\theta^2(n-2)} > \frac{1}{\theta^2 n}$ . Assim, não podemos afirmar se  $\hat{\theta}^*$  é ou não um ENVVUM para  $\frac{1}{\theta}$ .
- Exercício: para este modelo, encontrar  $LICR(\tau(\theta))$ , em que  $\tau(\theta) = \theta^2$  e  $\tau(\theta) = \frac{1}{\theta^2}$

- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim N(\mu, \sigma^2)$ , com  $\mu$  conhecido. Achar o  $LICR(\sigma^2)$ . Já vimos que:

$$\begin{aligned}
 S(\sigma^2) &= \frac{\partial}{\partial \sigma^2} \ln f_{\mathbf{X}}(\mathbf{x}; \sigma^2) = -\frac{n}{\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 \\
 &= \frac{n}{2(\sigma^2)^2} \left[ \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - \sigma^2 \right] \\
 &= a(\sigma^2)[t(\mathbf{X}) - \tau(\sigma^2)] \tag{9}
 \end{aligned}$$

Como  $\mathcal{E}[t(\mathbf{X})] = \mathcal{E}\left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2\right) = \sigma^2$  e por (9), temos que  $\mathcal{V}(t(\mathbf{X})) = LICR(\sigma^2)$  e, assim,  $t(\mathbf{X}) = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$  é um ENVVUM de  $\sigma^2$ , pelo colorário.

# LICR

- Exercício: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Poisson}(\theta)$ . Prove que se  $\hat{\theta} = \bar{X}$ , então  $\mathcal{V}(\hat{\theta}) = LICR(\theta)$ .
- Exemplo: Considere o modelo do exercício anterior e  $\tau(\theta) = e^{-\theta}(1 + \theta)$ .
- Note que  $P_\theta(X = 0) = e^{-\theta}$  e  $P_\theta(X = 1) = e^{-\theta}\theta$ .
- Defina  $T = I_{\{X=0 \cup X=1\}}$ . Assim,  
 $\mathcal{E}(T) = P_\theta(X = 0 \cup X = 1) = e^{-\theta} + e^{-\theta}\theta = e^{-\theta}(1 + \theta) = \tau(\theta)$ .
- Seja agora  $T^* = \frac{1}{n} \sum_{i=1}^n I_{\{X_i=0 \cup X_i=1\}}$ , assim  $\mathcal{E}(T^*) = \tau(\theta)$  e  
 $\mathcal{V}(T^*) = \frac{\tau(\theta)(1-\tau(\theta))}{n}$
- Por outro lado, vamos verificar se algum estimador não viciado de  $\tau(\theta)$ , neste caso, atinge o LICR.

# LICR

- Temos que  $S(\theta) = \frac{n}{\theta}[\bar{x} - \theta]$
- Se  $T$  é um estimador não viesado de  $\tau(\theta)$  cuja  $\mathcal{V}_\theta(T) = LICR(\tau(\theta))$ , então

$$\begin{aligned} a(\theta)[t(\mathbf{x}) - \tau(\theta)] &= \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) \\ t(\mathbf{x}) &= \frac{n}{\theta a(\theta)}[\bar{x} - \theta] + \tau(\theta) \\ &= \frac{n\bar{x}}{\theta a(\theta)} + \left[ \tau(\theta) - \frac{n}{a(\theta)} \right] \end{aligned}$$

- Mas para que  $t(\mathbf{x})$  seja uma estatística, devemos ter

$$\tau(\theta) - \frac{n}{a(\theta)} = 0 \rightarrow a(\theta) = \frac{\tau(\theta)}{n} \rightarrow t(\mathbf{x}) = \frac{n^2 \bar{x}}{\tau(\theta)}$$

o que é uma contradição. Logo,

$$\mathcal{V}(T) > LICR(\tau(\theta)), \forall \theta \in \Theta, \forall T, \mathcal{E}_\theta(T) = \tau(\theta)$$

# Teorema de Rao-Blackwell

- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Bernoulli}(\theta)$ ,  $\theta \in (0, 1)$ .  
Defina  $T = X_1$ ,  $S = \sum_{i=1}^n X_i$  e  $T^* = \mathcal{E}(T|S)$ . Note que

$$\begin{aligned}\mathcal{E}(T|S = s) &= P(X_1 = 1|S = s) = \frac{P(X_1 = 1, S = s)}{P(S = s)} = \\ &= \frac{P(X_1 = 1, \sum_{i=1}^n X_i = s)}{\binom{n}{s}\theta^s(1-\theta)^{n-s}} = \frac{P(X_1 = 1, \sum_{i=2}^n X_i = s-1)}{\binom{n}{s}\theta^s(1-\theta)^{n-s}} \\ &= \frac{\binom{n-1}{s-1}\theta^{s-1+1}(1-\theta)^{n-1-s+1}}{\binom{n}{s}\theta^s(1-\theta)^{n-s}} = \frac{s}{n} = \frac{\sum_{i=1}^n X_i}{n}\end{aligned}$$

Note que  $\mathcal{V}(X_1) = \theta(1-\theta) \geq \mathcal{V}(T^*) = \frac{\theta(1-\theta)}{n}$ ,  $\forall \theta \in \Theta$ .

# Teorema de Rao-Blackwell

- Seja  $T = t(\mathbf{X})$  um estimador não viciado para  $\tau(\theta), \forall \theta \in \Theta$  e  $S = s(\mathbf{X})$  uma estatística suficiente para  $\tau(\theta)$ . Defina  $T^* = \mathcal{E}(T|S)$ . Então:
  - 1)  $T^*$  é uma estatística.
  - 2)  $\mathcal{E}(T^*) = \tau(\theta), \forall \theta \in \Theta$ .
  - 3)  $\mathcal{V}(T^*) \leq \mathcal{V}(T), \forall \theta \in \Theta$ .
- Prova: 1) Segue do fato de que  $S$  é suficiente e  $T = t(\mathbf{X})$ .
- Prova: 2)  $\mathcal{E}(T^*) = \mathcal{E}(\mathcal{E}(T|S)) = \mathcal{E}(T) = \tau(\theta)$ , pois  $T$  é um env de  $\tau(\theta)$ .



# Teorema de Rao-Blackwell

- Prova: 3) Temos que

$$\begin{aligned}\mathcal{V}(T^*) &= \mathcal{V}(\mathcal{E}(T|S)) \\ \mathcal{V}(T) &= \mathcal{E}(\mathcal{V}(T|S)) + \mathcal{V}(\mathcal{E}(T|S)) \\ &= \underbrace{\mathcal{E}(\mathcal{V}(T|S))}_{\geq 0} + \mathcal{V}(T^*) \\ &\rightarrow \mathcal{V}(T) \geq \mathcal{V}(T^*)\end{aligned}$$

- Exercício: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Poisson}(\theta)$  e  $\tau(\theta) = e^{-\theta}(1 + \theta)$ . Obtenha, explicitamente,  $T^{**} = \mathcal{E}(T|S)$  em que  $T^* = \frac{1}{n} \sum_{i=1}^n I_{\{X_i=0 \cup X_i=1\}}$  e  $S = \sum_{i=1}^n X_i$ . Mostre que:  $\mathcal{V}(T^{**}) \leq \mathcal{V}(T^*)$ .

## Teorema de Rao-Blackwell (TRB)

- Observação: Se  $T$  é um estimador de  $\tau(\theta)$  (não necessariamente não viciado) e  $S$  é uma estatística suficiente, então  $\mathcal{E}_\theta[(T^* - \tau(\theta))^2] \leq \mathcal{E}_\theta[(T - \tau(\theta))^2], \forall \theta \in \Theta$  (EQM), em que  $T^* = \mathcal{E}(T|S)$ . Sugestão para demonstração:  $\mathcal{E}(T) = \mathcal{E}(T^*)$ .
- Exemplo (necessidade da Suficiência de  $S$ ): Seja  $X_1, X_2$  uma aa de  $X \sim N(\mu, \sigma^2)$ , da tamanho 2 e defina  $T = \frac{X_1 + X_2}{2}$ . Note que:

$$\begin{aligned}\mathcal{E}(T|X_1) &= \mathcal{E}\left[\left(\frac{X_1 + X_2}{2} \middle| X_1\right)\right] = \frac{1}{2}\mathcal{E}[\mathcal{E}(X_1|X_1) + \mathcal{E}(X_2|X_1)] \\ &= \frac{1}{2}(X_1 + \mu)\end{aligned}$$

que não é uma estatística ( $\mathcal{E}(T|X_1)$ ).

# Teorema

- Seja  $T$  um ENVVUM de  $\tau(\theta)$  ( $\mathcal{V}_\theta(T) \leq \infty$ ). Então  $T$  é único.
- Dem: Seja  $T'$  um outro ENVVUM de  $\tau(\theta)$  e defina  $T^* = \frac{T+T'}{2}$ .  
Assim

$$\mathcal{E}(T^*) = \tau(\theta)$$

e

$$\begin{aligned} \mathcal{V}(T^*) &= \frac{1}{4}\mathcal{V}(T) + \frac{1}{4}\mathcal{V}(T') + \frac{1}{2}\text{Cov}(T, T') \\ &\stackrel{\text{Cauchy-Schwarz}}{\leq} \frac{1}{4}\mathcal{V}(T) + \frac{1}{4}\mathcal{V}(T') + \frac{1}{2}(\mathcal{V}(T)\mathcal{V}(T'))^{1/2} \\ &\stackrel{\mathcal{V}(T)=\mathcal{V}(T')}{=} \mathcal{V}(T) \rightarrow \mathcal{V}(T^*) \leq \mathcal{V}(T), \forall \theta \in \Theta \end{aligned}$$

# Teorema

- No entanto, como  $T$  é ENVVUM,  $\mathcal{V}(T^*) = \mathcal{V}(T), \forall \theta \in \Theta$ . Por outro lado, isso implica que:

$$\begin{aligned} \frac{1}{4}\mathcal{V}(T) + \frac{1}{4}\mathcal{V}(T') + \text{Cov}(T, T') &= \\ \frac{1}{4}\mathcal{V}(T) + \frac{1}{4}\mathcal{V}(T') + (\mathcal{V}(T)\mathcal{V}(T'))^{1/2} & \end{aligned}$$

$$\text{Cov}(T, T') = (\mathcal{V}(T)\mathcal{V}(T'))^{1/2} (= \mathcal{V}(T))$$

→  $\text{Cov}(T, T') = \pm 1 \rightarrow \exists a(\theta), h(\theta)$  constantes,

$$T' = a(\theta)T + h(\theta) \rightarrow \mathcal{E}(T') = a(\theta)\tau(\theta) + h(\theta) \text{ e}$$

$$\mathcal{V}(T') = a^2(\theta)\mathcal{V}(T)$$

Assim, como  $T'$  também é um ENVVUM, temos que  $a(\theta) = 1$  e  $h(\theta) = 0, \forall \theta \in \Theta$ . Logo  $T = T'$ .

# Teorema de Lehmann-Scheffe

- Já vimos que, se existir, o ENVVUM é único.
- O LICR não, necessariamente, é útil, para obter o ENVVUM.
- O TRB apenas, em princípio, aperfeiçoa estimadores não viciados, no sentido de diminuir sua variâncias.
- O Teorema de Lehmann-Scheffe (TLS), sob certas condições, produz o ENVVUM.

# Teorema de Lehmann-Scheffe

- Seja  $S$  uma estatística suficiente e completa e  $T$  um estimador não viciado de  $\tau(\theta)$ , tal que,  $T = g(S)$ . Então  $T$  é o ENVVUM.
- Prova:
  - 1) Unicidade: Seja  $T'$  um outro ENVVUM, assim  $T' = h(S)$  (pelo TRB). Então, defina  $f(S) = T - T' = g(S) - h(S)$ . Portanto

Se,  $\mathcal{E}(f(S)) = 0 \rightarrow f(S) = 0, \forall a \in B_s$  (suporte de  $S$ ), pois  $S$  é completa

Logo,  $T - T' \equiv 0 \rightarrow T \equiv T', \forall \theta \in \Theta$ .

- 2) Existência: Seja  $T'$  um estimador não viciado de  $\tau(\theta)$ . Então  $T^* = \mathcal{E}(T|S)$  é um estimador não viciado de  $\tau(\theta)$  e  $\mathcal{V}_\theta(T^*) \leq \mathcal{V}_\theta(T), \forall \theta \in \Theta$ . Como  $T^*$  é uma função de  $S$ , pelo item 1), temos que  $T^* \equiv T$ . Assim,  $\mathcal{V}_\theta(T^*) = \mathcal{V}_\theta(T), \forall \theta \in \Theta$ .

# Teorema de Lehmann-Scheffe

- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \exp(\theta)$ ,  $\mathcal{E}(X) = \theta$  e defina  $\tau(\theta) = \frac{1}{\theta}$ . Já vimos que,  $\hat{\theta} = \frac{n-1}{n} \frac{1}{S}$  é uma estimador não viciado de  $\tau(\theta)$ .
- Como  $S$  é uma estatística suficiente e completa,  $\hat{\theta} = g(S)$  e  $\mathcal{E}(\hat{\theta}) = \tau(\theta)$ , pelo TLS, temos que  $\hat{\theta}$  é o ENVVUM de  $\tau(\theta)$ .
- Obs: Isso é verdade, ainda que

$$\mathcal{V}_\theta(\hat{\theta}) > LICR(\tau(\theta)), \forall \theta \in \Theta, \forall n \in \mathcal{N}.$$

o que, de fato, acontece neste caso.

## Exemplo

- Seja  $X_1, \dots, X_n$  uma aa de  $X \sim \text{Poisson}(\theta)$  e  $\tau(\theta) = e^{-\theta}(1 + \theta)$ .  
Obtenha o ENVVUM de  $\tau$ .
- Já vimos (fora deixado para ser provado) que

$$T^{**} = \mathcal{E}(T^*|S) = \left(\frac{n-1}{n}\right)^S \left(1 + \frac{S}{n-1}\right),$$

em que  $T^* = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{X_i=0 \cup X_i=1\}}$  e  $S = \sum_{i=1}^n X_i$ .



# Exemplo

- Logo,  $T^{**}$  é o ENVVUM de  $\tau(\theta)$ , pelo TLS, pois  $\mathcal{E}(T^{**}) = \mathcal{E}(T^*) = \tau(\theta)$  (como já vimos anteriormente) e  $T^{**} = g(S)$ ,  $S$  uma estatística suficiente e completa.
- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim U(0, \theta)$ ,  $\theta > 0$ . O ENVVUM de  $\theta$  é  $\hat{\theta} = \frac{n+1}{n} Y_n$ ,  $Y_n = \max\{X_1, \dots, X_n\}$ . Pelo TLS, como  $\mathcal{E}(\hat{\theta}) = \theta$  e  $\hat{\theta} = g(Y_n)$ , em que  $Y_n$  é uma estatística suficiente e completa.

# Formas de obter o ENVVUM ( $\tau(\theta)$ )

- 1) Obter uma estatística suficiente e completa ( $S$ ) e
  - 1.1) Construir um env, digamos,  $T$ , que seja função de  $S$  ( $T = g(S)$ ), tal que  $\mathcal{E}(T) = \tau(\theta)$  (TLS).
  - 1.2) Obter  $T = \mathcal{E}(T'|S)$ , em que  $T'$  é um unv de  $\tau(\theta)$  (TLS + TRB).
- 2) Calcular o LICR e provar que  $\mathcal{V}(T) = LICR(\tau(\theta))$ ,  $\forall \theta \in \Theta$ ,  $\mathcal{E}(T) = \tau(\theta)$  (env).
- 3) Provar que (sempre ocorre na FE, mas não necessariamente, o modelo precisa pertencer à FE):

$$a(\theta)[t(\mathbf{x}) - \tau(\theta)] = \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta)$$

$$\mathcal{E}(t(\mathbf{X})) = \tau(\theta), \forall \theta \in \Theta.$$

# Obtenção de Estatísticas Suficientes e Completas

- 1) Família exponencial regular (FEC não, necessariamente, apresenta uma estatística suficiente e completa).
- 2) Critério da fatoração (ou teorema da minimalidade e suficiência) & provar a completitude pela respectiva definição.

## Exemplo

- Seja  $X_1, \dots, X_n$  uma aa de  $X$ ,  $X \sim \exp(\theta)$ ,  $\mathcal{E}(X) = \theta$ . Defina  $\tau(\theta) = e^{-1/\theta}$ . Obtenha o ENVVUM de  $\tau(\theta)$ .
- Note que:

$$F_X(x; \theta) = 1 - e^{-x/\theta} \rightarrow P(X > 1) = 1 - F_X(1; \theta) = e^{-1/\theta}.$$

- Por outro lado, defina:

$$T = \begin{cases} 1, & \text{se } X_1 > 1 \\ 0, & \text{caso contrário.} \end{cases}$$

- Assim,  $\mathcal{E}_\theta(T) = P(X_1 > 1) = e^{-1/\theta}$ .
- Segundo o TLS (TRB),  $T^* = \mathcal{E}(T|S)$  é o ENVVUM de  $\tau(\theta)$ , em que  $S = \sum_{i=1}^n X_i$ .

## Exemplo

- Mas, note que:

$$\mathcal{E}(T|S = s) = P(X_1 > 1|S = s) = \int_1^{\infty} f(x_1|s)dx_1 = \int_1^{\infty} \frac{f(x_1, s)}{f(s)}dx_1 \quad (10)$$

- Vamos encontrar  $f(x_1, s)$ . Para isso, defina  $Y_1 = X_1$ ,  $Y_2 = X_1 + T_2 = S$ ,  $T_2 = \sum_{i=2}^n X_i$ . Por outro lado,

$$f_{\mathbf{Y}}(y_1, y_2) = |\mathbf{J}|f_{(X_1, T_2)}(y_1, y_2 - y_1)\mathbb{1}_A(\mathbf{y})$$

item Assim  $x_1 = y_1$ ,  $t_2 = y_2 - y_1$ ,  $\rightarrow$

$$\mathbf{J} = \begin{bmatrix} 1 & 0 \\ -1 & 1 \end{bmatrix}$$

# Exemplo

- Portanto,

$$\begin{aligned}f_{\mathbf{Y}}(y_1, y_2) &= f_{X_1}(y_1)f_{T_2}(y_2 - y_1)\mathbb{1}_{(0, \infty)}(y_1)\mathbb{1}_{(y_1, \infty)}(y_2) \\&= \frac{1}{\theta}e^{-y_1/\theta} \frac{1}{\theta^{n-1}\Gamma(n-1)} e^{-\frac{(y_1+y_2)}{\theta}} (y_2 - y_1)^{n-2} \mathbb{1}_{(0, y_2)}(y_1) \\&\times \mathbb{1}_{(0, \infty)}(y_2) \\&= \frac{1}{\theta}e^{-y_2/\theta} \frac{1}{\theta^{n-1}\Gamma(n-1)} (y_2 - y_1)^{n-2} \mathbb{1}_{(0, y_2)}(y_1)\mathbb{1}_{(0, \infty)}(y_2)\end{aligned}$$

- Dessa forma,

$$f_{Y_1|Y_2}(y_1|y_2) = \frac{n-1}{y_2^n} \left( \frac{y_2 - y_1}{y_2} \right)^{n-2} \mathbb{1}_{(0, y_2)}(y_1)$$

$$f_{X_1|S}(x_1|s) = \frac{n-1}{s^n} \left( \frac{s - x_1}{s} \right)^{n-2} \mathbb{1}_{(0, s)}(x_1)$$

# Exemplo

- Assim,

$$\begin{aligned}\mathcal{E}(T|S = s) &= \int_1^\infty \frac{n-1}{s^{n-1}} (s-x_1)^{n-2} \mathbb{1}_{(0,s)}(x_1) dx_1 \\ &= \frac{n-1}{s^{n-1}} \int_1^s (s-x_1)^{n-2} dx_1 \stackrel{u=s-x_1}{=} \frac{(s-1)^{n-1}}{s^{n-1}} \\ &= \left(1 - \frac{1}{s}\right)^{n-1}, s > 1\end{aligned}$$

# Exemplo

- Logo,

$$\mathcal{E}(T|S) = \begin{cases} (1 - \frac{1}{S})^{n-1}, & \text{se } s = \sum_{i=1}^n x_i > 1 \\ 0, & \text{caso contrário} \end{cases}$$

- Exercício: Seja  $X_1, \dots, X_n$  uma aa de  $X_i \sim \text{Poisson}(\lambda_i)$ ,  $\lambda_i = e^{\theta z_i}$ ,  $z_i; i = 1, 2, \dots, n$  são conhecidos. Encontre o  $LICR(\tau(\theta)) = \theta$ .



# Definição

- Def: Sejam  $\hat{\theta}_1$  e  $\hat{\theta}_2$  dois estimadores não viciados de  $\tau(\theta)$ . Suponha que suas variâncias sejam ambas finitas. A eficiência de  $\hat{\theta}_1$  relativa a  $\hat{\theta}_2$  é definida como sendo:

$$\text{eff}_\theta = \frac{\mathcal{V}_\theta(\hat{\theta}_1)}{\mathcal{V}_\theta(\hat{\theta}_2)}, \forall \theta \in \Theta$$

- Dizemos que  $\hat{\theta}_1$  é mais eficiente do que  $\hat{\theta}_2$  se  $\text{eff} \leq 1, \forall \theta \in \Theta \leftrightarrow \mathcal{V}_\theta(\hat{\theta}_1) \leq \mathcal{V}_\theta(\hat{\theta}_2), \forall \theta \in \Theta$ .

# Definição

- Def: Seja  $\hat{\theta}$  um env de  $\tau(\theta)$  e suponha que  $f_{\mathbf{X}}(\cdot; \theta)$ ,  $\theta \in \Theta$ , satisfaz as condições de regularidade. Dizemos que  $\hat{\theta}$  é um estimador eficiente se

$$\mathcal{V}(\hat{\theta}) = \frac{[\tau'(\theta)]^2}{I(\theta)}, \forall \theta \in \Theta$$

ou seja, atinge o  $LICR(\tau(\theta))$ .

## Definição

- Def: Seja  $\hat{\theta}$  um estimador eficiente (se existir). A eficiência de um estimador não viciado,  $\hat{\theta}_1$  (se existir) é definido como:

$$\text{eff}_{\theta}(\hat{\theta}_1) = \frac{\mathcal{V}_{\theta}(\hat{\theta}_1)}{\mathcal{V}_{\theta}(\hat{\theta})}, \forall \theta \in \Theta.$$

Caso não exista um estimador eficiente (como na definição acima) definimos a eficiência como:

$$\text{eff}_{\theta}(\hat{\theta}_1) = \frac{\mathcal{V}_{\theta}(\hat{\theta}_1)}{\text{LICR}(\tau(\theta))}, \forall \theta \in \Theta$$

desde que  $f_{\mathbf{X}}(\cdot; \theta)$  satisfaça as CR.

- OBS: Seja  $t(\mathbf{X})$  um env de  $\tau(\theta)$ ,  $\mathcal{V}_{\theta}(t(\mathbf{X})) = \text{LICR}(\tau(\theta))$  e  $f_{\mathbf{X}}(\cdot; \theta)$  satisfazendo as CR. Então  $\mathbf{X}$  pertence à FE e  $t(\mathbf{X})$  é suficiente.

Prova: [Bickel & Doksum \(2015\)](#).

# Definição

- Obs: O TLS também é válido no caso multiparamétrico (multivariado), ou seja  $\theta \in \Theta \subseteq \mathcal{R}^k$ . Seja  $\tau(\theta) : \Theta \rightarrow \mathcal{R}$ ,  $\mathbf{S} = (S_1, \dots, S_k)'$  uma estatística suficiente e completa. Seja  $T = g(\mathbf{S})$ ,  $\mathcal{E}(T) = \tau(\theta)$ . Então T é o ENVVUM de  $\tau(\theta)$ .
- Exemplo: Seja  $X_1, \dots, X_n$  uma aa de  $X \sim N(\mu, \sigma^2)$ . Sabemos que  $\mathbf{S} = (\bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2)'$  é uma estatística suficiente e completa.
- Então, seja  $\hat{\mu} = \bar{X}$  e  $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ .
- Como  $\mathcal{E}(\hat{\mu}) = \mu$  e  $\mathcal{E}(\hat{\sigma}^2) = \sigma^2$ , e ambos são funções de  $\mathbf{S}$ . Logo  $\hat{\mu}$  e  $\hat{\sigma}^2$  são os ENVVUM's de  $\mu$  e  $\sigma^2$ , respectivamente, pelo TLS.