

Métodos de estimação (pontual)

Prof. Caio Azevedo

Introdução

- Nosso objetivo é inferir (conjecturar a respeito do verdadeiro (ou verdadeiros) valor(es) de θ - 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 parâmetros θ associado à uma população de interesse.
- **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, obtem-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 θ (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 θ , 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: $f_{\hat{\theta}}(\tilde{\theta}; \theta)$.
- 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:
 $\mathcal{RQM}_{\theta}(\hat{\theta}) = \sqrt{\mathcal{EQM}_{\theta}(\hat{\theta})}$ (menor possível).



Características e qualidade dos estimadores

- Valor absoluto do vício relativo: $\mathcal{VAVR}_\theta(\hat{\theta}) = \frac{|\mathcal{B}_\theta(\hat{\theta})|}{|\theta|}$ (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: $\hat{\theta} \xrightarrow[n \rightarrow \infty]{D} D(\theta)$.

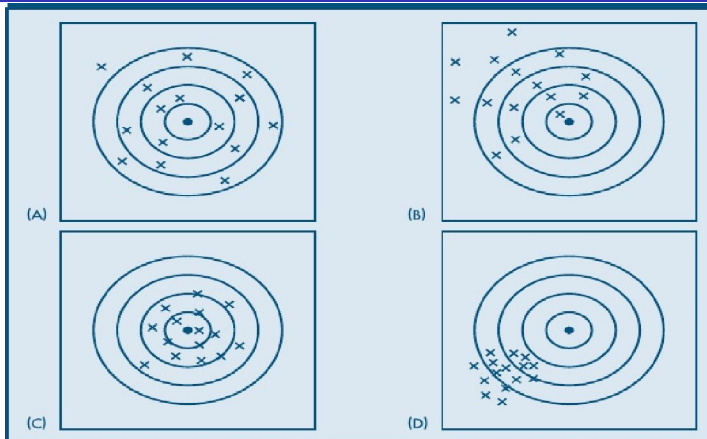
Características e qualidade dos estimadores

- 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 do 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



(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 de que, sob certas condições de que

$$\frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow[n \rightarrow \infty]{P} \mathcal{E}(X^k).$$

- Não, necessariamente, leva à estimadores ótimos.
- Vimos que:
 - Em geral, são facilmente obteníveis.
 - 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.

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 vamos supor 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 $\frac{\partial}{\partial \theta_i} h_j(\boldsymbol{\theta})$, $i, j = 1, 2, \dots, k$ e contínua em $\boldsymbol{\theta}$.

- Então,


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

- Em que $\boldsymbol{\Sigma}_{i,j} = [\mu_{i+j} - \mu_i \mu_j]$, em que $\mu_i = \mathcal{E}(X^i)$, $\forall i$. Demonstração Sen & Singer (1994). Large sample methods in Statistics: An introduction with applications.

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 σ^2 , através de um dos dois seguintes estimadores:
 $\hat{\sigma}_1^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ 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, como
 $\lim_{n \rightarrow \infty} \frac{\hat{\sigma}_1^2}{\hat{\sigma}_2^2} = \lim_{n \rightarrow \infty} \frac{n-1}{n} = 1$ (assintoticamente equivalentes).
- Sabemos que $\frac{n-1}{\sigma^2} \hat{\sigma}_2^2 \sim \chi_{(n-1)}^2$.
- 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, $\mathcal{E}QM(\hat{\sigma}_1^2) = \frac{2n-1}{n^2} (\sigma^2)^2$ e $\mathcal{E}QM(\hat{\sigma}_2^2) = \mathcal{V}(\hat{\sigma}_2^2) = \frac{2(\sigma^2)^2}{n-1}$.
- Portanto, note que $\frac{\mathcal{E}QM(\hat{\sigma}_1^2)}{\mathcal{E}QM(\hat{\sigma}_2^2)} = \frac{(2n-1)(n-1)}{2n^2} < 1 \rightarrow n > 1/3$.

Comparação dos EQM's



Métodos de máxima verossimilhança

- Vimos anteriormente que, para uma aa de tamanho 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


$$L(\theta; \mathbf{x}) \equiv L(\theta).$$

- A verossimilhança nos fornece, então, a probabilidade de observar uma dada amostra em função do θ 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 θ , obteremos o valor mais provável responsável pela geração de uma dada amostra.


Métodos de máxima verossimilhança

- Exemplo: Seja $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$. Considere duas situações, uma em que $n = 10$ $\mathbf{x} = (0, 0, 1, 0, 0, 1, 0, 0, 1, 0)'$, $\Theta = \{0, 3; 0, 6\}$ e um outro com $n=100$ valores simulados de uma $\text{Bernoulli}(0, 3)$, $\Theta = (0, 1)$.
- Exemplo: 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 $\exp(10)$.


Exemplo 1 (Bernoulli)



Exemplo 2 (Bernoulli)



Exemplo exponencial



Métodos de máxima verossimilhança

- Caso discreto: $f_{\mathbf{X}}(\mathbf{x}; \theta) = P_{\theta}(\mathbf{X} = \mathbf{x})$.
- Caso contínuo:

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

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

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

é chamado de estimador de máxima verossimilhança de θ (pode haver somente um, mais de um, infinitos ou nenhum).

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

Métodos 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 θ , 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 θ .

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 θ .
- 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 θ .
- Assim $\hat{\theta}$, $\forall Y_n - \alpha < \hat{\theta} < Y_1 + \alpha$, será um EMV de θ , 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 $\mathcal{B}(\hat{\theta}_{MV}) = -\frac{\theta}{n+1}$.

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

- Variância: $\mathcal{V}(\hat{\theta}_{MM}) = \frac{\theta^2}{3n}$ e $\mathcal{V}(\hat{\theta}_{MV}) = \frac{n\theta^2}{(n+1)^2(n+2)}$.
- EQM: $\mathcal{EQM}(\hat{\theta}_{MM}) = \mathcal{V}(\hat{\theta}_{MM}) = \frac{\theta^2}{3n}$ e $\mathcal{EQM}(\hat{\theta}_{MV}) = \mathcal{V}(\hat{\theta}_{MV}) + \mathcal{B}^2(\hat{\theta}_{MV}) = \frac{2\theta^2}{(n+2)(n+1)}$.
- Assim $\frac{\mathcal{EQM}(\hat{\theta}_{MM})}{\mathcal{EQM}(\hat{\theta}_{MV})} = \frac{(n+1)(n+2)}{6n} > 1 \Leftrightarrow n^2 - 3n + 2 > 0$ (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 θ 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, $\hat{\theta}$ 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 θ e, assim $\hat{\theta}$ é o EMV de θ .

- 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 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 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 θ e, portanto, $\hat{\theta}$ é o emv de θ .

Exemplo

- Note que $\mathcal{E}(\hat{\theta}) = \theta$ e $\mathcal{V}(\hat{\theta}) = \frac{\theta(1-\theta)}{n}$ (veja os slides http://www.ime.unicamp.br/~cnaber/aula_Intro_Inf_Mest_2S_2019.pdf) 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 θ . Seja $\tilde{\theta}$ o **valor** de θ que satisfaz:

$$\left\{ \begin{array}{l} \frac{\partial l(\theta)}{\partial \theta_1} = 0 \\ \frac{\partial l(\theta)}{\partial \theta_2} = 0 \\ \vdots \\ \frac{\partial l(\theta)}{\partial \theta_k} = 0 \end{array} \right. \quad (1)$$

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

Resultado

- Se além da condição (4) ser satisfeita, tivermos ($k=2$) que:

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

e

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

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

Resultado

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

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

seja negativa definida (veja http://www.ime.unicamp.br/~cnaber/aula_Intro_Ana_Multi_2S_2017.pdf).

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

- Além disso, temos que,

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

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

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 θ e, portanto $\hat{\mu} = \bar{X}$ e $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$.
- Exercício: obtenha os emv de θ , 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) α conhecido, ii) γ conhecido e iii) ambos desconhecidos

Exemplo

- Exemplo 5: Seja X uma va com distribuição hipergeométrica (N, n, a) 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

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

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.
- Conseqüentemente, 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,

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

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.

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 λ (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 η .

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 $\tau(\hat{\theta}) = (\tau_1(\hat{\theta}), \dots, \tau_k(\hat{\theta}))'$.
- Graficamente, veja o slide seguinte (precisamos particionar o espaço paramétrico associado à η).
- Dem: Defina $L^*(\eta) = \sup_{\theta: \tau(\theta)=\eta} L(\theta)$, $\eta \in \Lambda$, a verossimilhança de η induzida por τ .
- 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

$$L(\tilde{\eta}) = \sup_{\eta \in \Lambda} L^*(\eta) = \sup_{\eta \in \Lambda} \sup_{\theta \in \Theta_{\eta}} L(\theta) = \sup_{\theta \in \Theta} L(\theta) = L(\tilde{\theta}) \quad (2)$$

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

$$L(\tilde{\theta}) = \sup_{\theta \in \Theta_{\tilde{\eta}}} L(\theta) = L(\tau(\tilde{\theta})) \quad (3)$$

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

- Assim, de (2) e (3) temos que $L(\tilde{\eta}) = L(\tau(\tilde{\theta}))$ e, assim, $\tau(\tilde{\theta})$ é a env 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 θ , 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 θ 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 θ , então $\hat{x}_q = -\bar{X} \ln(1 - q)$ é o emv de x_q .

Exemplo

- Seja X_1, \dots, X_n uma a ade $X \sim U(\theta - 1/2, \theta + 1/2)$. Já provamos (págs.23 e 24) que se $Y_n - \frac{1}{2} < \hat{\theta} < Y_n + \frac{1}{2}$, $\hat{\theta}$ é o emv de θ .
- 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 θ .
- Contudo, $\hat{\theta}_\gamma = Y_n - \frac{1}{2} + \cos^2(X_1)(1 + Y_1 - Y_n)$ é um emv de θ , mas $\hat{\theta}_\gamma \neq g(Y_1, Y_n)$ ($\hat{\theta}_\gamma = g(Y_1, Y_n, X_1)$).
- Isto ocorre, essencialmente, pela 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, $f_X(x; \theta) = \frac{\alpha\beta^\alpha}{x^{\alpha+1}} \mathbf{1}_{[\beta, \infty]}(x)$. 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 precisa pertencer à família de localização-escala).
- 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 ξ_1, \dots, ξ_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 Θ , $\forall i$ (pelo menos duas vezes).

Método de mínimos quadrados (MMQ)

- A estimativa de MQ de θ 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 θ . Portanto, se $\tilde{\theta}$ é a eqm de θ , 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.

Método de mínimos quadrados (MMQ)

- Podemos estimar σ^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 θ (exercício). Se, além disso, $\xi \stackrel{iid}{\sim} N(0, \sigma^2)$, então $\hat{\theta} = \bar{Y}$ também é o emv de θ .
- 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 emv de θ .
- Neste caso, se $\xi_i \stackrel{iid}{\sim} N(0, \sigma^2)$, $\hat{\theta} = (\hat{\alpha}, \hat{\beta})'$ também é o emv de θ (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 θ 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: <https://www.aeaweb.org/articles?id=10.1257/jep.15.4.143>

Multiplicadores de Lagrange

- As vezes, temos interesse em obter os estimadores de θ , 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 de 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: http://www.ime.unicamp.br/~cnaber/aula_DPD_ADD_1S_2017.pdf

- 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

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

- 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 θ_i , $i = 1, 2, \dots, K$.
- Inferência Estatística restrita: https://www.amazon.com/Constrained-Statistical-Inference-Inequality-Constraints/dp/B01A651NR2/ref=sr_1_fkmr0_1?keywords=silvapulle+book+restricted+inference&qid=1568384293&s=gateway&sr=8-1-fkmr0

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 θ . 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 comparar estimadores, segundo alguns critérios como valor esperado, variância e EQM.
- Nesta parte aprofundaremos tal discussão.
- Suponha que queremos estimar θ , 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 às 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, gostar-se-ia que $\mathcal{E}(\hat{\theta}) \cong \theta$ e $\mathcal{V}(\hat{\theta}) \approx 0$ (pequena).

Comparação de estimadores

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

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

- Exemplo 1: Seja $X_i \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$, então $\hat{\theta} = \bar{X}$ é um estimador não viciado de θ .
- 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 θ pois, apesar de \bar{X} ser não viciado para μ , $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ é viciado para σ^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 afirma que um polinômio de grau n seja 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 $\mathcal{EQM}_\theta(\hat{\theta}) = \mathcal{E}_\theta[(\hat{\theta} - \theta)^2]$.
- 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 θ , 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 $\mathcal{E}QM(\hat{\theta}_2) = \frac{n}{4(\sqrt{n}+n)^2}$.
- Graficamente (slides seguinte).
- Exercício: obter os pontos $\{a_n, b_n\}$, em relação à θ , tais que $\mathcal{E}QM(\hat{\theta}_1) = \mathcal{E}QM(\hat{\theta}_2)$ ($\alpha = \beta = \frac{\sqrt{n}}{2}$).
- Assim, em termos do $\mathcal{E}QM$, 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 θ e n



Definições

- Se $\hat{\theta}_1$ e $\hat{\theta}_2$ são dois estimadores de θ , 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 viciados de $\tau(\theta)$ e vamos supor que $C_\tau \neq \emptyset$. Nosso objetivo é encontrar $\hat{\theta}^*$ em C_τ ,

$$\mathcal{V}(\hat{\theta}^*) \leq \mathcal{V}(\hat{\theta}), \forall \theta \in \Theta, \forall \hat{\theta}^* \neq \hat{\theta} \quad (4)$$

- Definição: um estimador pertencente à C_τ que satisfaz a (4) é dito ser um estimador não viciado 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

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

\exists e são contínuas em θ

3)

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

Condições de regularidade

- Exercício : mostrar que a distribuição $U(0, \theta)$ não satisfaz as condição de regularidade (CR).
- Exercícios: Mostrar que
 - a) $\mathcal{E} \left[\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right] = 0$.
 - b) $\mathcal{E} \left[-\frac{\partial^2}{\partial \theta^2} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right] = \mathcal{E} \left[\left(\frac{\partial}{\partial \theta} \ln f(\mathbf{X}; \theta) \right)^2 \right]$.
- Vamos demonstrar o item b)

■ Note que

$$\begin{aligned} \mathcal{E} \left(-\frac{\partial^2}{\partial \theta^2} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right) &= - \int_{\mathcal{R}^n} \frac{\partial^2}{\partial \theta^2} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \\ &= - \int_{\mathcal{R}^n} \frac{\partial}{\partial \theta} \frac{\frac{\partial}{\partial \theta} f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{x}; \theta)} f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \\ &= - \int_{\mathcal{R}^n} \frac{1}{f_{\mathbf{X}}^2(\mathbf{X}; \theta)} \left[\left(\frac{\partial^2}{\partial \theta^2} f_{\mathbf{X}}(\mathbf{x}; \theta) \right) f_{\mathbf{X}}(\mathbf{x}; \theta) - \left(\frac{\partial}{\partial \theta} f_{\mathbf{X}}(\mathbf{x}; \theta) \right)^2 \right] f_{\mathbf{X}}(\mathbf{X}; \theta) d\mathbf{x} \\ &= - \underbrace{\int_{\mathcal{R}^n} \frac{\partial^2}{\partial \theta^2} f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x}}_0 + \int_{\mathcal{R}^n} \left(\frac{\frac{\partial}{\partial \theta} f_{\mathbf{X}}(\mathbf{x}; \theta)}{f_{\mathbf{X}}(\mathbf{x}; \theta)} \right)^2 f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \\ &= \int_{\mathcal{R}^n} \left(\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) \right)^2 f_{\mathbf{X}}(\mathbf{X}; \theta) = \mathcal{E} \left[\left(\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta) \right)^2 \right] = I(\theta) \end{aligned}$$

Teorema de Cramer-Rao

- Seja $\mathbf{X} = (X_1, \dots, X_n)'$ uma aa de $f_{\mathbf{X}}(\cdot; \theta)$, $\theta \in \Theta$ 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:

$$\mathcal{V}(T) \geq \frac{\left[\frac{d}{d\theta}\tau(\theta)\right]^2}{I(\theta)}, \forall \theta \in \Theta \quad (5)$$

- Obs: As distribuições pertencentes à FE satisfazem as CR $\frac{d}{d\theta}\tau(\theta) = \tau'(\theta)$.
- A inequação (8) é conhecida como limite inferior de Cramer-Rao (LICR).
- Assim, todo e qualquer estimador não viciado cuja variância atingir o LICR será um ENVUM.

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,

$$\text{Cov}^2 \left(t(\mathbf{X}), \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right) \leq \mathcal{V}(t(\mathbf{X})) \mathcal{E} \left[\left(\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta) \right)^2 \right] \quad (6)$$

Teorema de Cramer-Rao

- Mas

$$\begin{aligned}\text{Cov}\left(t(\mathbf{X}), \frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{X}; \theta)\right) &= \int_{\mathcal{R}^n} t(\mathbf{x}) \left(\frac{\partial}{\partial \theta} \ln f_{\mathbf{X}}(\mathbf{x}; \theta)\right) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} \\ &= \frac{\partial}{\partial \theta} \int_{\mathcal{R}^n} t(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}; \theta) d\mathbf{x} = \frac{\partial}{\partial \theta} \mathcal{E}(t(\mathbf{X})) \\ &= \tau'(\theta)\end{aligned}\quad (7)$$

- Logo, de (7) em (6) 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

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

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

- Basta notar que $f_X(\mathbf{x}; \theta) = \prod_{i=1}^n f_X(x_i; \theta)$ e as variáveis associadas são iid.
- Corolário: Sob as condições do teorema,

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

Teorema de Cramer-Rao

- Prova: Note que

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

- A igualdade (no LICR) ocorre se $\text{Cov}(Y, W) = 1$ (estando Y e W padronizadas), ou seja se $Y = aW + b$, para algum vetor (a, b) . Ou seja, se e somente se, \exists constantes $a^*(\theta)$ e $b^*(\theta)$

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

ou

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

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

- 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:

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

- 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 ENVUM para θ .

- 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, $\mathcal{E}(\hat{\theta}^2) = \frac{n^2}{\theta^2(n-1)(n-2)}$. 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 ENVUM 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 μ conhecido. Achar o $LICR(\sigma^2)$. Já vimos que:

$$\begin{aligned}
 S(\sigma^2) &= \frac{\partial}{\partial \sigma^2} \ln f_{\mathbf{X}}(\mathbf{x}; \sigma^2) = -\frac{n}{\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 \\
 &= \frac{n}{2(\sigma^2)^2} \left[\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - \sigma^2 \right] \\
 &= a(\sigma^2)[t(\mathbf{X}) - \tau(\sigma^2)]
 \end{aligned} \tag{8}$$

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 (8), 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 ENVUM de σ^2 , pelo colorário.

- 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, 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 $\mathcal{E}_\theta[(T^* - \tau(\theta))] \leq \mathcal{E}_\theta[(T - \tau(\theta))], \forall \theta \in \Theta$ (EQM), em que $T^* = \mathcal{E}(T|S)$. Sugestão: $\mathcal{E}(T) = \mathcal{E}(T^*)$.
- 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 ENVUM de $\tau(\theta)$ ($\mathcal{V}_\theta(T) \leq \infty$). Então T é único.
- Dem: Seja T' um outro ENVUM de $\tau(\theta)$ e defina $T^* = \frac{T+T'}{2}$. Assim

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

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

Teorema

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

$$\begin{aligned} \text{Cov}(T, T') &= (\mathcal{V}(T)\mathcal{V}(T'))^{1/2} (= \mathcal{V}(T)) \\ &\rightarrow \text{Cov}(T, T') = \pm 1 \rightarrow \exists a(\theta), h(\theta) \text{ constantes,} \\ &\quad T' = a(\theta)T + h(\theta) \\ &\rightarrow \mathcal{E}(T') = a(\theta)\tau(\theta) + h(\theta) \text{ e} \\ &\quad \mathcal{V}(T') = a^2(\theta)\mathcal{V}(T) \end{aligned}$$

Assim, como T' também é um ENVUM, 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 ENVUM é único.
- O LICR não, necessariamente, é útil, para obter o ENVUM.
- 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 ENVUM.

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 ENVUM.

- Prova:

- 1) Unicidade: Seja T' um outro ENVUM, 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

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

- 2) 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 ENVUM 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 ENVUM de τ .
- 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 $S = \sum_{i=1}^n X_i$.

- Logo, T^{**} é o ENVUM 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 ENVUM de θ 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 ENVUM ($\tau(\theta)$)

- 1) Obter uma estatística suficiente e completa (S) e
 - 1.1) Construir uma 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 ENVUM 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, temos que:

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

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

Exemplo

- Mas, note que:

$$\mathcal{E}(T|S = s) = P(X_1 > 1|S = s) = \int_1^{\infty} f(x_1|s)dx_1 = \int_1^{\infty} \frac{f(x_1, s)}{f(s)}dx_1 \quad (9)$$

- 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,

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

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

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

Exemplo

- Portanto,

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

- Dessa forma,

$$\begin{aligned}f_{Y_1|Y_2}(y_1|y_2) &= \frac{n-1}{y_2^n} \left(\frac{y_2 - y_1}{y_2}\right)^{n-2} \mathbb{1}_{(0, y_2)}(y_1) \\f_{X_1|S}(x_1|s) &= \frac{n-1}{s^n} \left(\frac{s - x_1}{s}\right)^{n-2} \mathbb{1}_{(0, s)}(x_1)\end{aligned}$$

Exemplo

- Assim,

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

- Logo,

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

- Exercício: Seja X_1, \dots, X_n uma aa de $X \sim \text{Poisson}(\lambda_i)$, $\lambda_i = e^{\theta z_i}$, $z_i; i = 1, 2, \dots, n$ 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 $\mathcal{V}_\theta(\hat{\theta}_1)$ é mais eficiente do que $\mathcal{V}_\theta(\hat{\theta}_2)$ 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:

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

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

- OBS: Seja $t(\mathbf{X})$ um env de $\tau(\theta)$, $\mathcal{V}_{\theta}(t(\mathbf{X})) = LICR(\tau(\theta))$ 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 ENVUM 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 ENVUM's de μ e σ^2 , respectivamente, pelo TLS.