

2 Estimação Paramétrica Pontual

2.1 Introdução

2.1.1 Aspectos Gerais

Situamo-nos no âmbito da inferência paramétrica:

- População X tem distribuição na família $\mathcal{F} = \{f(\cdot | \theta) : \theta \in \Theta\}$
- Espaço do paramétrico $\Theta \subset \mathbb{R}^k$
- Define-se processo de amostragem; em geral (X_1, \dots, X_n) amostra casual de tamanho n proveniente de X
- Espaço amostral \mathcal{X}

Problema:

- estimar θ pontualmente, ou seja, escolher uma aplicação $\mathbf{x} \in \mathcal{X} \mapsto T(\mathbf{x}) \in \Theta$ que a cada amostra observada faz corresponder um valor para o parâmetro
- A aplicação T é uma estatística a que se dá o nome de estimador de θ ; cada ponto $T(\mathbf{x})$ é designado por estimativa
- Podemos por vezes estar interessados em estimar uma função de θ , $\tau(\theta)$

Exemplo 2.1 *Admite-se que X , o número de sinistros originados anualmente por uma apólice de seguro automóvel, tem distribuição de Poisson de parâmetro (desconhecido) $\lambda > 0$.*

Podemos estar interessados em estimar λ . Um estimador natural é $T(X_1, \dots, X_n) = \bar{X}$; a estimativa de λ associada é $T(x_1, \dots, x_n) = \bar{x}$.

*Em vez de focarmos o nosso interesse no número médio de sinistros por apólice, podemos estar interessados em $\tau(\lambda) = e^{-\lambda}$ que traduz a probabilidade de não se verificar nenhum sinistro:
 $P(X = 0 | \lambda) = e^{-\lambda}$.* ■

A definição de estimador é extremamente geral:

- o que se entende por um “bom” estimador? — critérios de optimalidade
- métodos de construção de estimadores

2.1.2 Suficiência

- Conceito cujo interesse extravasa o problema da estimação pontual
- Ideia intuitiva: uma estatística é suficiente para o parâmetro θ se retira da amostra aleatória X_1, \dots, X_n toda a informação relevante que esta contém sobre o parâmetro desconhecido θ

Exemplo 2.1 (Continuação) *Suponhamos que se observa o número de sinistros associados a $n = 10$ apólices de seguro automóvel, x_1, \dots, x_{10} , e que se anota que $\sum_{i=1}^{10} x_i = 14$. Devido a um erro no sistema informático da seguradora, perde-se a amostra x_1, \dots, x_{10} . Os responsáveis pelo erro pretendem produzir uma amostra x_1^*, \dots, x_{10}^* tal que $\sum_{i=1}^{10} x_i^* = 14$ e que seja estatisticamente indistinguível da originalmente observada. Isso é possível?*

Seja $T = \sum_{i=1}^n X_i$ e $n = 10$. Qual a distribuição de $X_1, \dots, X_n \mid T = 14$?

$$\begin{aligned}
 P(X_1 = x_1, \dots, X_n = x_n \mid T = 14) &= \frac{P(X_1 = x_1, \dots, X_n = x_n, T = 14)}{P(T = 14)} \\
 &= \begin{cases} \frac{P(X_1 = x_1, \dots, X_n = x_n)}{P(T = 14)} & \text{se } \sum_{i=1}^n x_i = 14 \\ 0 & \text{se } \sum_{i=1}^n x_i \neq 14 \end{cases} \\
 &= \frac{e^{-n\lambda} \lambda^{\sum x_i} / \prod x_i!}{e^{-n\lambda} (n\lambda)^{14} / 14!} \quad \text{se } \sum_{i=1}^n x_i = 14 \\
 &= \frac{14!}{\prod_{i=1}^n x_i!} \frac{1}{n} \cdots \frac{1}{n} \quad \text{se } \sum_{i=1}^n x_i = 14
 \end{aligned}$$

Ou seja, $X_1, \dots, X_n \mid T = 14$ segue uma distribuição multinomial com vector de probabilidade $\psi = (1/n, \dots, 1/n)$. Esta distribuição não depende de λ ! Sabendo que se observaram 14 sinistros, não é necessário conhecer λ para gerar a amostra x_1^*, \dots, x_n^* .

Diz-se neste caso que T é suficiente para λ : toda a informação relevante sobre λ disponível em X_1, \dots, X_n está contida em T .

Definição 2.1 Estatística suficiente: Seja (X_1, \dots, X_n) uma amostra casual proveniente de uma população $\mathcal{F} = \{f(\cdot | \theta) : \theta \in \Theta\}$. Diz-se que a estatística T é suficiente para \mathcal{F} (ou, simplesmente, para θ) se a distribuição de (X_1, \dots, X_n) condicionada por $T = t$ não depende de θ , $\forall \theta \in \Theta$ e $\forall t$. ■

Exemplo 2.2 Seja (X_1, \dots, X_n) uma amostra casual de dimensão $n > 3$ proveniente de uma população $B(1, \theta)$.

Note-se que

$$f(x_1, \dots, x_n | \theta) = \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}, \quad x_i = 0, 1, \quad i = 1, \dots, n.$$

Como $T = \sum_{i=1}^n X_i \sim B(n, \theta)$, tem-se que, se $\sum_{i=1}^n x_i = t$

$$f(x_1, \dots, x_n | t) = 1 / \binom{n}{t}$$

que não depende de θ . Toda a informação relevante sobre θ contida em (X_1, \dots, X_n) está condensada em T : T é suficiente para θ .

Qualquer função biunívoca de T é também suficiente para θ , por exemplo \bar{X} .

$S = X_1 + X_2$ não é suficiente para θ : se $S = s$,

$$f(x_1, \dots, x_n | s) = \theta^{\sum_{i=3}^n x_i} (1 - \theta)^{n-2-\sum_{i=3}^n x_i} / \binom{2}{s}$$



A definição de suficiência é útil para verificar se determinada estatística, cuja distribuição por amostragem conhecemos, é ou não suficiente para θ . A sua utilidade na pesquisa de estatísticas suficientes é limitada.

Teorema 2.1 Critério da Factorização: *A estatística T é suficiente para θ se e só se existem duas funções não negativas $g(\cdot)$ e $h(\cdot)$ tais que para todo o x_1, \dots, x_n*

$$f(x_1, \dots, x_n \mid \theta) = g[T(x_1, \dots, x_n), \theta] \times h(x_1, \dots, x_n) .$$



Note-se que $g(\cdot)$ depende de (x_1, \dots, x_n) unicamente através de $T(x_1, \dots, x_n)$, e de θ , enquanto que $h(\cdot)$ depende unicamente de (x_1, \dots, x_n) .

Exemplo 2.3 *Seja (X_1, \dots, X_n) uma amostra casual de dimensão n proveniente de uma população $Po(\lambda)$. Então,*

$$\begin{aligned} f(x_1, \dots, x_n \mid \lambda) &= \prod_{i=1}^n e^{-\lambda} \frac{\lambda^{x_i}}{x_i!} \\ &= e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i} \times \left(\prod_{i=1}^n x_i! \right)^{-1} \end{aligned}$$

Pelo Critério da Factorização, $T = \sum_{i=1}^n X_i$ é suficiente para λ .



Exemplo 2.4 X_1, \dots, X_n amostra casual proveniente de população $N(\mu, \sigma^2)$. Então,

$$\begin{aligned} f(x_1, \dots, x_n \mid \mu, \sigma^2) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{1}{2\sigma^2} (x_i - \mu)^2 \right] \\ &= (2\pi\sigma^2)^{-n/2} \exp[-n\mu^2/(2\sigma^2)] \exp \left[-\frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i^2 - 2n\mu \sum_{i=1}^n x_i \right) \right] \end{aligned}$$

logo $(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2)$ é suficiente para (μ, σ^2) , e conseqüentemente (\bar{X}, S'^2) também é suficiente para (μ, σ^2) .

Exemplo 2.5 X_1, \dots, X_n amostra casual proveniente de população $U(0, \theta)$, $\theta > 0$.

$$\begin{aligned} f(x_1, \dots, x_n \mid \theta) &= \prod_{i=1}^n \frac{1}{\theta} \quad \text{se } x_i \in (0, \theta), \quad i = 1, \dots, n \\ &= \theta^{-n} \prod_{i=1}^n I_{(0, \theta)}(x_i) \\ &= \theta^{-n} I_{(-\infty, \theta)}(x_{(n)}) \times I_{(0, +\infty)}(x_{(1)}) \end{aligned}$$

concluindo-se que $X_{(n)}$ é suficiente para θ . ■

2.1.3 Verosimilhança e Informação

Consideremos modelos uniparamétricos $\mathcal{F} = \{f(\cdot | \theta) : \theta \in \Theta\}$, onde $\Theta \subset \mathbb{R}$. Seja X_1, \dots, X_n uma amostra casual de tamanho n proveniente de \mathcal{F} .

Definição 2.2 Verosimilhança: *Observada uma amostra (x_1, \dots, x_n) , a correspondente função de verosimilhança de θ é dada por*

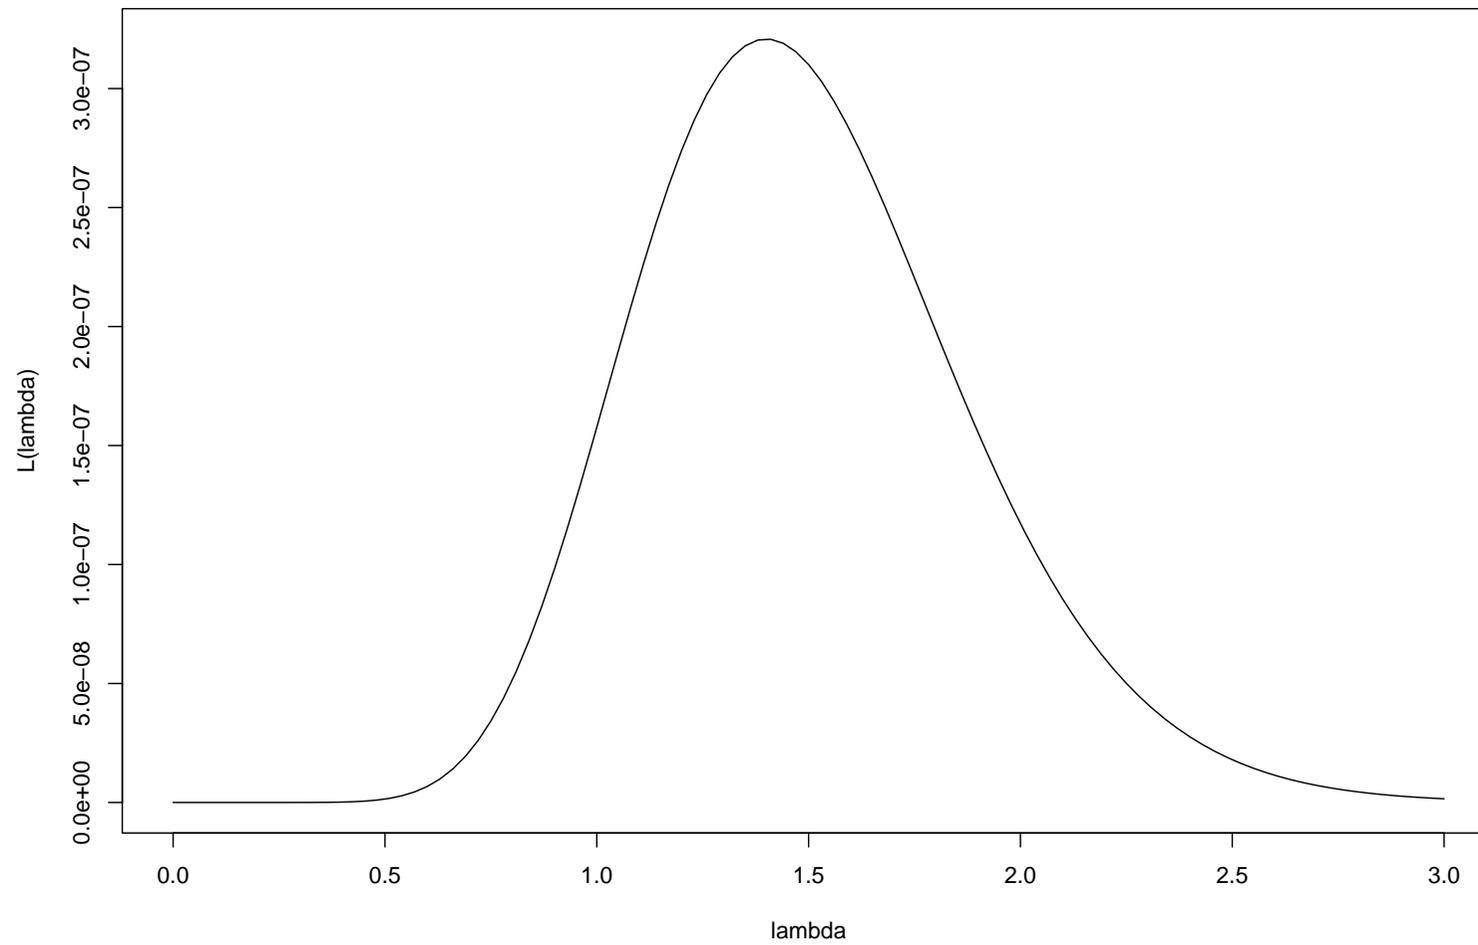
$$\begin{aligned} L(\theta | x_1, \dots, x_n) &= f(x_1, \dots, x_n | \theta) \\ &= \prod_{i=1}^n f(x_i | \theta) . \end{aligned}$$



Como x_1, \dots, x_n está fixo, é comum escrever-se $L(\theta)$.

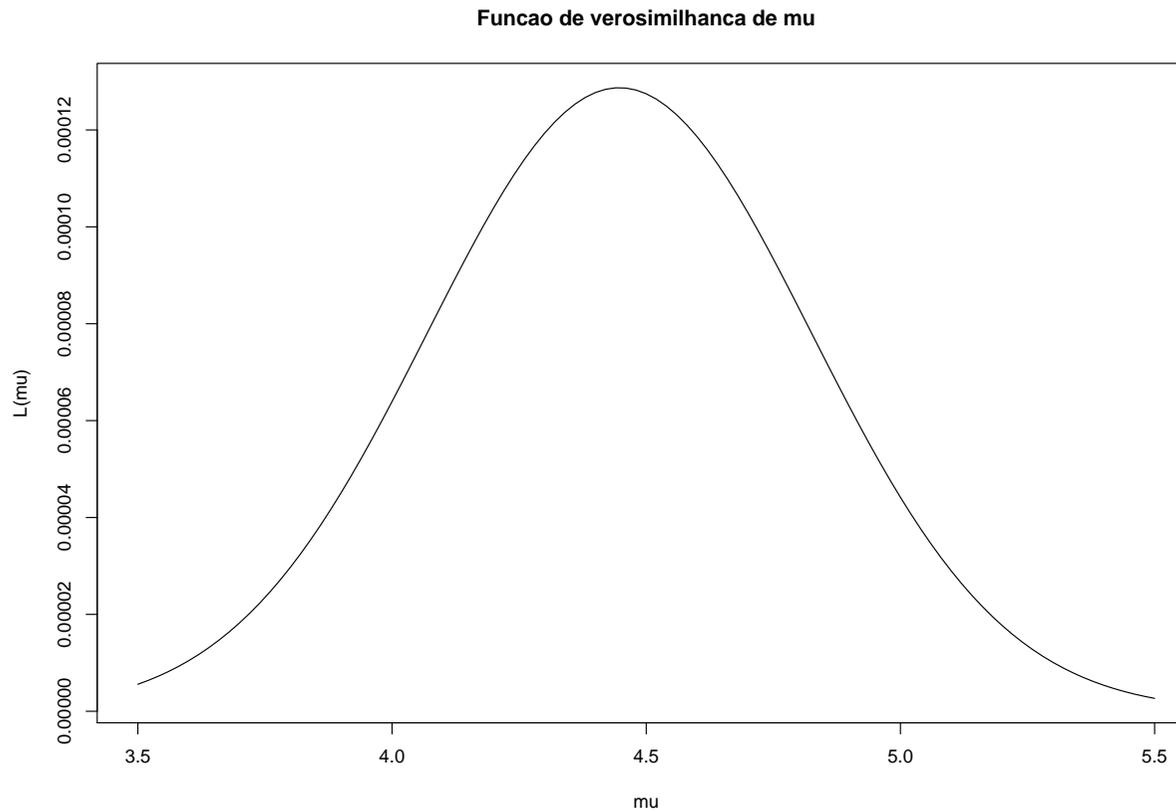
Exemplo 2.6 *Suponha-se que $X | \lambda \sim Po(\lambda)$ representa o número de sinistros originados anualmente por uma apólice de seguro automóvel. Observa-se uma amostra casual de tamanho $n = 10$ tal que $\sum_{i=1}^n x_i = 14$ e $\prod x_i! = 288$. Tem-se $L(\lambda) = \exp(-10\lambda)\lambda^{14}/288$.*

Funcao de verosimilhanca de lambda



Exemplo 2.7 *Suponha-se que $X \mid \mu \sim N(\mu, 1)$ e que se observou a amostra $(3.38, 5.93, 4.75, 3.77, 4.18, 5.29, 3.83)$. Como $\bar{x} = 4.45$ e $\sum x_i^2 = 143.49$, segue-se que*

$$L(\mu) = (2\pi)^{-7/2} \exp \left[-\frac{1}{2} (143.49 - 2 \times 7 \times 4.45\mu + 7\mu^2) \right]$$



Observação importante: A verosimilhança não é uma função (densidade de) probabilidade e portanto não tem uma escala natural associada. Está definida portanto a menos de uma constante multiplicativa:

$$L(\theta \mid x_1, \dots, x_n) \propto f(x_1, \dots, x_n \mid \theta)$$

constante essa que pode depender de x_1, \dots, x_n mas que não depende de θ . O que tem significado são razões de verosimilhança

$$\frac{L(\theta' \mid x_1, \dots, x_n)}{L(\theta^* \mid x_1, \dots, x_n)}$$

medindo quão verosímil é θ' comparativamente com θ^* à luz dos dados observados x_1, \dots, x_n .

Condições de regularidade

C1— Θ é um intervalo aberto de \mathbb{R} .

C2—O conjunto $\{x : f(x | \theta) > 0\}$, i.e., o suporte de $f(\cdot | \theta)$, não depende de θ .

C3—A função $f(x | \theta)$, $x \in \mathcal{X}$, $\theta \in \Theta$, é diferenciável em ordem a θ para todo o x

C4—Tem-se que $0 < E [\partial \ln f(X | \theta) / \partial \theta]^2 < +\infty$ para todo o θ

C5—A permutação de $\frac{\partial}{\partial \theta}$ and $\int dx$ é válida.

Observações:

- C2 exclui modelos como $U(0, \theta)$: $\theta > 0$
- C4 garante que a v.a. $S = \partial \ln f(X | \theta) / \partial \theta$ tem segundo momento finito.

Definição 2.3 Função Score: *Observada a amostra x_1, \dots, x_n , a função score destina-se a medir a variação relativa da função de verosimilhança em função de θ :*

$$S(\theta | x_1, \dots, x_n) = \frac{L'(\theta | x_1, \dots, x_n)}{L(\theta | x_1, \dots, x_n)} = \frac{\partial \ln L(\theta | x_1, \dots, x_n)}{\partial \theta}.$$



Nota: Para uma amostra casual, tem-se $S(\theta | x_1, \dots, x_n) = \sum_{i=1}^n S(\theta | x_i)$ onde $S(\theta | x_i)$ é a função score associada à i -ésima observação.

Teorema 2.2 *Verificando-se as condições de regularidade, tem-se que para todo o $\theta \in \Theta$*

$$E[S(\theta | X_1, \dots, X_n)] = 0 .$$



Definição 2.4 Medida de informação de Fisher: *A quantidade de informação de Fisher sobre θ contida na observação de X_1, \dots, X_n é definida por*

$$\mathcal{I}_{(X_1, \dots, X_n)}(\theta) = E \{ [S(\theta | X_1, \dots, X_n)]^2 \}$$

Propriedades:

- Verificando-se as condições de regularidade, $\mathcal{I}_{(X_1, \dots, X_n)}(\theta) = \text{Var}[S(\theta | X_1, \dots, X_n)]$
- No caso de uma amostra casual, $\mathcal{I}_{(X_1, \dots, X_n)}(\theta) = n\mathcal{I}_{X_i}(\theta)$
- Fórmula útil para o cálculo de \mathcal{I} : verificando-se as condições de regularidade,

$$\mathcal{I}_{(X_1, \dots, X_n)}(\theta) = -E \left[\frac{\partial^2 \ln f(X_1, \dots, X_n | \theta)}{\partial \theta^2} \right]$$

Teorema 2.3 *Sendo $T(X_1, \dots, X_n)$ uma estatística, tem-se que*

$$\mathcal{I}_{(X_1, \dots, X_n)}(\theta) \geq \mathcal{I}_T(\theta)$$

verificando-se a igualdade se e só se T for suficiente para θ .

Exemplo 2.8 Seja X_1, \dots, X_n uma amostra aleatória proveniente de uma população $Po(\lambda)$, $\lambda > 0$.
Então,

$$S(\lambda \mid x_1, \dots, x_n) = \frac{n}{\lambda}(\bar{x} - \lambda)$$

logo,

$$\mathcal{I}_{(X_1, \dots, X_n)}(\lambda) = \left(\frac{n}{\lambda}\right)^2 \text{Var}(\bar{X}) = \frac{n}{\lambda}.$$

É fácil ver que $\mathcal{I}_{(X_1, \dots, X_n)}(\lambda) = n\mathcal{I}_{X_i}(\lambda)$.

Além disso,

$$\frac{\partial}{\partial \lambda} S(\lambda \mid x_1, \dots, x_n) = -\frac{\sum x_i}{\lambda^2}$$

pelo que

$$E \left[-\frac{\partial^2 \ln f(X_1, \dots, X_n \mid \lambda)}{\partial \lambda^2} \right] = \frac{n}{\lambda} = \mathcal{I}_{(X_1, \dots, X_n)}(\lambda)$$



2.2 Critérios de optimalidade

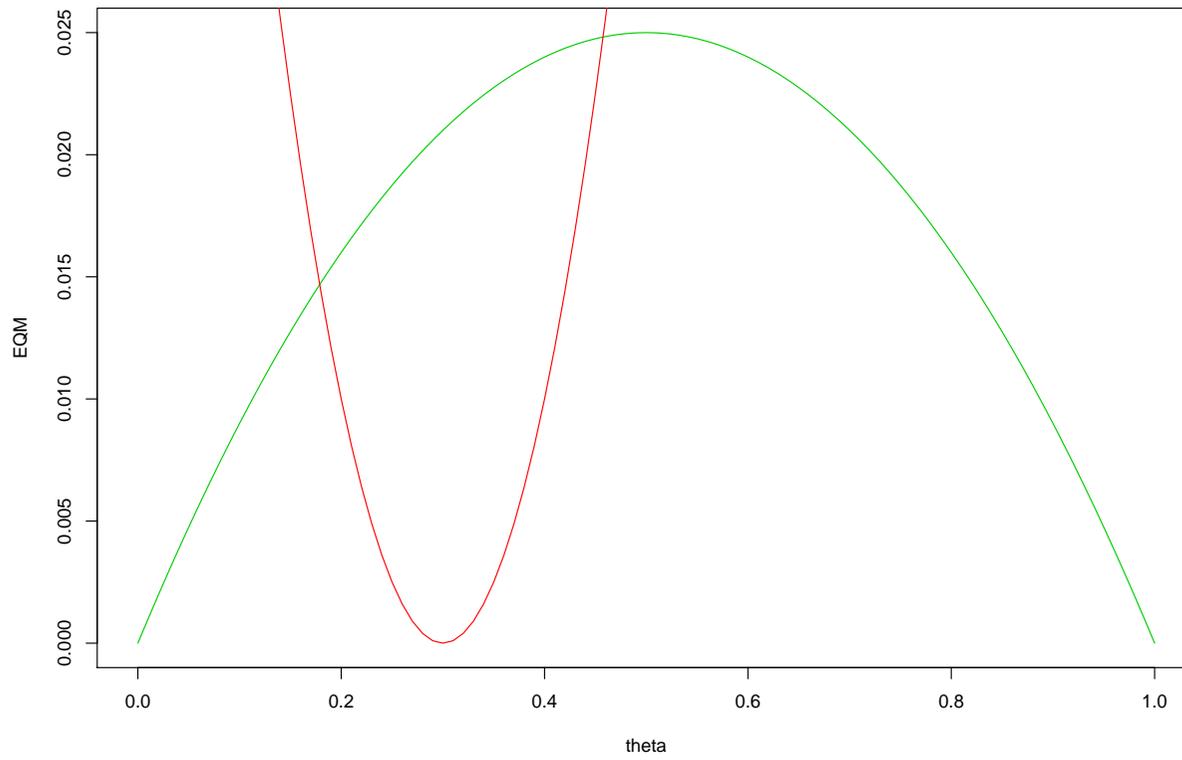
- A avaliação da qualidade de um estimador faz-se considerando a população de estimativas que gera, ou seja, a sua distribuição por amostragem. Avalia-se o estimador e não a estimativa.
- A existência de um estimador que seja ‘ideal’ é facilmente rebatida:

Exemplo 2.9 *Considere-se uma população $B(1, \theta)$ e uma amostra casual X_1, \dots, X_n dela extraída. É natural considerar que um estimador T é ‘melhor’ que um estimador S como estimadores de θ se*

$$E[(T - \theta)^2] \leq E[(S - \theta)^2] \quad \forall \theta$$

ou seja, se o erro quadrático médio de T nunca é superior ao de S .

Seja $T = \bar{X}$ e considere-se $S = 0.3$. Claramente, $EQM_\theta(T) = \theta(1 - \theta)/n$ e $EQM_\theta(S) = (\theta - 0.3)^2$. ■



2.2.1 Centragem

Definição 2.5 Estimador centrado: *Um estimador T diz-se um estimador centrado de $\tau(\theta)$ sse*

$$E[T] = \tau(\theta) \quad \forall \theta \in \Theta$$



Observações

- significa na prática que se se utilizar T para estimar $\tau(\theta)$ um número muito grande de vezes, então a média das estimativas obtidas estará próxima de $\tau(\theta)$ qualquer que seja θ
- $b_\theta(T) = E[T] - \tau(\theta)$ - enviesamento ou viés. Estimador não centrado diz-se enviesado.
- Nem sempre existem: observa-se $X \sim B(1, \theta)$ e pretende-se um estimador centrado de θ^2 , $T(X)$. Então, deve ter-se, $\forall \theta$

$$\theta^2 = T(1)\theta + T(0)(1 - \theta) \Leftrightarrow \theta^2 = [T(1) - T(0)]\theta + T(0)$$

o que é impossível.

- A média amostral é sempre um estimador centrado da média da população, caso esta exista
- A variância amostral corrigida é sempre um estimador centrado da variância da população, caso esta exista

2.2.2 Eficiência

Definição 2.6 *Sejam T e T^* estimadores centrados de $\tau(\theta)$. Dizemos que T é mais eficiente que T^* na estimação de $\tau(\theta)$ se*

$$\text{Var}(T) \leq \text{Var}(T^*) \quad \forall \theta \in \Theta$$

O estimador de $\tau(\theta)$ centrado T é o mais eficiente se qualquer que seja T^ , estimador centrado de $\tau(\theta)$, se tem que T é mais eficiente que T^* . ■*

Teorema 2.4 Desigualdade de Fréchet-Cramer-Rao: *Considere-se uma população verificando as condições de regularidade, e seja $\tau(\theta)$ uma função real e diferenciável de θ . Seja ainda T um estimador centrado de $\tau(\theta)$ com variância finita. Se, $\forall \theta \in \Theta$*

$$E \left[\left| T(X_1, \dots, X_n) \frac{\partial \ln f(X_1, \dots, X_n | \theta)}{\partial \theta} \right| \right] < +\infty$$

$$E \left[T(X_1, \dots, X_n) \frac{\partial \ln f(X_1, \dots, X_n | \theta)}{\partial \theta} \right] = \frac{\partial}{\partial \theta} E[T(X_1, \dots, X_n)]$$

caso em que T se diz regular, então

$$\text{Var}(T) \geq \frac{[\tau'(\theta)]^2}{\mathcal{I}_{(X_1, \dots, X_n)}(\theta)} .$$



Observações:

- No caso em que $\tau(\theta) = \theta$ e X_1, \dots, X_n é amostra casual de população X , tem-se para qualquer estimador (regular) centrado de θ , T ,

$$\text{Var}(T) \geq [n\mathcal{I}_X(\theta)]^{-1}$$

- O limite inferior de FCR só é válido caso se verifiquem as condições de regularidade
- Mesmo verificando-se as condições de regularidade, não existem garantias de que exista um estimador centrado de $\tau(\theta)$ cuja variância atinja o limite inferior de FCR
- ao quociente entre o limite inferior de FCR e a variância de um estimador centrado de $\tau(\theta)$ dá-se o nome de eficiência (absoluta):

$$e_\theta(T) = \frac{[\tau'(\theta)]^2 / \mathcal{I}_{(X_1, \dots, X_n)}(\theta)}{\text{Var}(T)}$$

Se as condições de regularidade forem satisfeitas, tem-se que $0 \leq e_\theta(T) \leq 1$. Se $e_\theta(T) = 1$, T é necessariamente o estimador mais eficiente na estimação de $\tau(\theta)$.

- Fala-se ainda de eficiência assintótica, $e_\theta^*(T) = \lim_{n \rightarrow +\infty} e_\theta(T)$, e em estimadores assintoticamente mais eficientes.

Exemplo 2.10 *Seja X_1, \dots, X_n uma amostra casual de tamanho n proveniente de uma população $Po(\lambda)$. Vimos que $\mathcal{I}_X(\lambda) = 1/\lambda$, logo qualquer estimador centrado de λ , T , verifica*

$$\text{Var}[T] \geq \lambda/n$$

Consequentemente, \bar{X} é o estimador mais eficiente de λ .

Qualquer estimador centrado de $\tau(\lambda) = e^{-\lambda} = P(X = 0)$, S , verifica

$$\text{Var}(S) \geq \lambda e^{-2\lambda}/n .$$

Exemplo 2.11 *Seja $X \sim U(0, \theta)$, $\theta > 0$ e considere-se*

$$T = \frac{n+1}{n} X_{(n)} .$$

Verifica-se que T é centrado para θ e que $\text{Var}(T) = \theta^2/[n(n+1)]$. Além disso, $\mathcal{I}_{(X_1, \dots, X_n)}(\theta) = n\theta^{-2}$ (calculada como se as condições de regularidade estivessem verificadas), pelo que

$$\text{Var}(T) < \text{LIFCR}.$$

Não estão satisfeitas as condições de regularidade. ■

Em que condições existem estimadores mais eficientes para $\tau(\theta)$? Corolário do Teorema de Frechét-Cramer-Rao:

Teorema 2.5 *Seja $T = T(X_1, \dots, X_n)$ um estimador regular não enviesado de $\tau(\theta)$. T é mais eficiente se e só se existir $\beta(\theta)$ tal que*

$$S(\theta \mid x_1, \dots, x_n) = \beta(\theta)[T(x_1, \dots, x_n) - \tau(\theta)] .$$



Observações:

- se existir um estimador mais eficiente para $\tau(\theta)$, este será necessariamente suficiente
- caso não exista um estimador mais eficiente para $\tau(\theta)$, o conceito de eficiência (absoluta) deixa de fazer sentido
- eficiência relativa: T e T^* estimadores centrados, a eficiência de T^* relativamente a T é definida por

$$e_{\theta}(T^*, T) = \frac{\text{Var}(T)}{\text{Var}(T^*)}$$

Exemplo 2.12 Se $X \sim B(1, \theta)$,

$$S(\theta | x_1, \dots, x_n) = \frac{n}{\theta(1-\theta)}(\bar{x} - \theta)$$

logo, \bar{X} é o estimador mais eficiente para θ . ■

Exemplo 2.13 Considere-se o modelo Cauchy de parâmetro de localização θ e parâmetro de escala 1, ou seja, $f(x | \theta) = \{\pi[1 + (x - \theta)^2]\}^{-1}$. Tem-se

$$S(\theta | x_1, \dots, x_n) = 2 \sum_{i=1}^n \frac{x_i - \theta}{1 + (x_i - \theta)^2} .$$

Não existe estimador mais eficiente de θ . ■

2.2.3 Erro quadrático médio

Como comparar estimadores enviesados em termos da dispersão em torno de $\tau(\theta)$?

Definição 2.7 Erro quadrático médio *O erro quadrático médio de um estimador T de $\tau(\theta)$ é definido por*

$$EQM_{\theta}(T) = E[(T - \tau(\theta))^2] .$$



Observações:

- T será superior a T^* em erro quadrático médio na estimação de $\tau(\theta)$ se $EQM_{\theta}(T) \leq EQM_{\theta}(T^*)$, $\forall \theta \in \Theta$
- Pela desigualdade de Markov, $P(|T - \tau(\theta)| > \varepsilon) \leq EQM_{\theta}(T)/\varepsilon^2$
- Tem-se que

$$EQM_{\theta}(T) = \text{Var}(T) + [b_{\theta}(T)]^2$$

- População normal: $E[S'^2] = \sigma^2$ e $E[S^2] = (n - 1)\sigma^2/n$, no entanto,

$$\frac{2\sigma^4}{n - 1} = \text{Var}(S'^2) = EQM_{\sigma^2}(S'^2) > EQM_{\sigma^2}(S^2) = \frac{2\sigma^4}{n} - \frac{\sigma^4}{n^2}$$

2.2.4 Consistência

Comportamento probabilístico do estimador à medida que $n \rightarrow +\infty$: seja $T_n = T(X_1, \dots, X_n)$

Definição 2.8 Consistência: O estimador T_n diz-se (fracamente) consistente para $\tau(\theta)$ se, $\forall \theta \in \Theta$,

$$\forall \varepsilon > 0 \lim_{n \rightarrow +\infty} P(|T_n - \tau(\theta)| > \varepsilon) = 0$$

ou seja, se $\forall \theta \in \Theta, T_n \xrightarrow{P} \tau(\theta)$. ■

Definição 2.9 Consistência em média quadrática: O estimador T_n diz-se consistente em média quadrática para $\tau(\theta)$ se, $\forall \theta \in \Theta$,

$$\lim_{n \rightarrow +\infty} E[(T_n - \tau(\theta))^2] = 0$$

ou seja, se $\forall \theta \in \Theta, T_n \xrightarrow{mq} \tau(\theta)$. ■

Observações:

- Pela desigualdade de Markov,

$$P(|T_n - \tau(\theta)| > \varepsilon) \leq E[(T_n - \tau(\theta))^2]/\varepsilon^2 = \text{EMQ}_\theta(T_n)/\varepsilon^2$$

logo consistência em média quadrática implica consistência (fraca)

- Como $E[(T_n - \tau(\theta))^2] = \text{Var}(T_n) + [b_\theta(T)]^2$ segue-se que uma condição suficiente para que T_n seja consistente na estimação de $\tau(\theta)$ é que

$$\begin{aligned} \lim_{n \rightarrow +\infty} E[T_n] &= \tau(\theta) \\ \lim_{n \rightarrow +\infty} \text{Var}[T_n] &= 0 \end{aligned}$$

- A consistência (mesmo em média quadrática) é uma propriedade pouco restritiva: se T_n é consistente, também o é $T_n^* = \frac{n-a}{n-b}T_n$.
- Exemplo: a média amostral é um estimador consistente (em média quadrática, logo fracamente também) da média da população desde que esta exista.

2.3 Métodos de estimação

2.3.1 Método dos momentos

- Ideia: obter o estimador dos parâmetros da população igualando os momentos amostrais aos momentos populacionais
- Seja $\theta = (\theta_1, \dots, \theta_k)$ o vector de parâmetros desconhecidos da população
- $\mu'_r = E[X^r]$ será uma função conhecida de θ : $\mu'_r = \psi_r(\theta_1, \dots, \theta_k)$
- Considere-se os correspondentes momentos amostrais $M'_r = \sum_{i=1}^n X_i^r / n$ e forme-se o sistema de equações $M'_r = \psi_r(\theta_1, \dots, \theta_k)$, $r = 1, \dots, k$
- A solução deste sistema, que se assume existir e ser única, é designada por $\tilde{\Theta}_r = \varphi(X_1, \dots, X_n)$ e dizemos que os estimadores $\tilde{\Theta}_1, \dots, \tilde{\Theta}_k$ de θ foram obtidos pelo método dos momentos.

Exemplo 2.14 Seja X_1, \dots, X_n uma amostra casual proveniente de uma população $N(\mu, \sigma^2)$. Sabemos que $\mu = \mu'_1$ e que $\sigma^2 = \mu'_2 - (\mu'_1)^2$. O sistema é então

$$\begin{cases} M'_1 = \mu'_1 = \mu \\ M'_2 = \mu'_2 = \sigma^2 + \mu^2 \end{cases}$$

e a solução é que o estimador do método dos momentos de μ é $M'_1 = \bar{X}$ e que o de σ^2 é $M'_2 - (M'_1)^2 = S^2$. ■

Exemplo 2.15 Considere-se uma população $X \sim G(\alpha, \lambda)$. Sabemos que $\mu'_1 = \alpha/\lambda$ e que $\text{Var}(X) = \mu'_2 - (\mu'_1)^2 = \alpha/\lambda^2$. Segue-se que o estimador do método dos momentos de (α, λ) é a solução do sistema

$$\begin{cases} M'_1 = \mu'_1 = \alpha/\lambda \\ M'_2 = \mu'_2 = \alpha/\lambda^2 + (\alpha/\lambda)^2 \end{cases}$$

ou seja, $(\bar{X}^2/S^2, \bar{X}/S^2)$. ■

2.3.2 Método da máxima verosimilhança

- Ideia: propor como estimativa de θ o valor $\hat{\theta}$ que maximiza a função de verosimilhança.
- A estimativa de MV, se existir, é $\hat{\theta}$ tal que

$$L(\hat{\theta} \mid x_1, \dots, x_n) \geq L(\theta \mid x_1, \dots, x_n) \quad \forall \theta \in \Theta$$

- a correspondente variável aleatória determina o estimador de máxima verosimilhança.

Observações:

- na maior parte dos casos, é mais fácil maximizar o logaritmo da função de verosimilhança
- frequentemente, mas nem sempre, isso faz-se calculando os zeros da função score:

$$\frac{d \ln L(\theta \mid x_1, \dots, x_n)}{d\theta} = 0$$

e verificando que nesse ponto a segunda derivada é negativa

- Os estimadores de MV podem não ser únicos: amostra casual de dimensão n proveniente de população $U(\theta - 1/2, \theta + 1/2)$, $\theta > 0$
- Nem sempre existe solução explícita, o que implica recorrer a métodos numéricos— e.g. função `nlm` no R (*non-linear minimization*)

Exemplo 2.16 X_1, \dots, X_n amostra casual de dimensão n proveniente de uma população $Po(\lambda)$

$$L(\lambda | x_1, \dots, x_n) \propto e^{-n\lambda} \lambda^{\sum x_i}$$

$$\ln L(\lambda | x_1, \dots, x_n) = c - n\lambda + n\bar{x} \ln \lambda$$

$$\frac{d \ln L}{d\lambda} = -n + n\bar{x}/\lambda$$

pelos que a função score tem um zero em $\hat{\lambda} = \bar{x}$. É fácil verificar que se trata de um ponto de máximo de $\ln L$, pelo que o estimador de MV de λ é \bar{X} . ■

Exemplo 2.17 X_1, \dots, X_n amostra casual de dimensão n proveniente de uma população $G(\alpha, \lambda)$ com λ conhecido. Determinar estimativa de MV de α :

$$L(\alpha | x_1, \dots, x_n) \propto \frac{\lambda^{n\alpha}}{\Gamma(\alpha)^n} \left(\prod x_i \right)^{\alpha-1}$$

$$\ln L(\alpha | x_1, \dots, x_n) = c + n\alpha \ln \lambda - n \ln \Gamma(\alpha) + (\alpha - 1) \sum \ln x_i$$

$$\frac{d \ln L}{d\alpha} = n \ln \lambda - n \frac{\Gamma'(\alpha)}{\Gamma(\alpha)} + \sum \ln x_i$$

os zeros da função score têm de ser calculados numericamente

Propriedades dos EMV:

- Se $\hat{\theta}$ for o estimador de MV de θ e se $\tau(\theta)$ for uma função biunívoca de θ , então $\tau(\hat{\theta})$ será estimador de MV de $\tau(\theta)$ — Invariância dos estimadores de MV que pode generalizar-se a situações onde $\tau(\theta)$ não é biunívoca
- Se T for suficiente, e se existir estimador de MV de θ , este é função de T
- O estimador mais eficiente para $\tau(\theta)$, se existir, é estimador de MV de $\tau(\theta)$
- Verificando-se determinadas condições de regularidade, o estimador de MV de θ , $\hat{\theta}$, é tal que

$$\sqrt{\mathcal{I}_{(X_1, \dots, X_n)}(\theta)}(\hat{\theta} - \theta) \stackrel{a}{\sim} N(0, 1)$$

- No resultado acima é possível substituir $\mathcal{I}_{(X_1, \dots, X_n)}(\theta)$
 - por $\mathcal{I}_{(X_1, \dots, X_n)}(\hat{\theta})$, a informação de Fisher avaliada no estimador de MV
 - pela *informação de Fisher observada*

$$H(\theta) = -\frac{\partial^2 \ln L}{\partial \theta^2}(\hat{\theta} | x_1, \dots, x_n)$$

quantidades estas que não dependem de θ .

- O resultado acima garante que $\hat{\theta}$ é consistente e assintoticamente mais eficiente