

Procedimento: Máxima Verossimilhança

- procedimento aplicável (faz sentido) em modelos paramétricos regulares.
  - Seja  $p(x|\theta) \in \mathcal{P} = \{p_\theta, \theta \in \Theta\}$  ;  $p(x|\theta)$  : densidade de  $X=x$  dada q'  $\theta$  e' o verdadeiro valor ;  $\theta \in \Theta$   
 $\Theta \subset \mathbb{R}^d$
- $L_x(\theta) = p(x|\theta)$  ← Verossimilhança de  $\theta$ .  
 ↳ medida de quan provável é q'  $\theta$  tenha produzido a observação  $x$ .

Método: Achar  $\hat{\theta}(x)$  q' maximize  $L_x(\theta)$  como função de  $\theta$ .

$$x \in \mathbb{X}; L_x(\cdot) : \Theta \rightarrow \mathbb{R}.$$

$\hat{\theta}(x)$  verifica . ie  $\hat{\theta}(x) = \operatorname{argmax}_{\theta \in \Theta} \{p(x|\theta)\}$

$$L_x(\hat{\theta}(x)) = p(x|\hat{\theta}(x)) = \max_{\theta} \{p(x|\theta), \theta \in \Theta\}$$

Exemplo: Suponha q'  $\theta \in \Theta = \{0, 1/2\}$  e  $p(x|\theta)$  é dada pela seguinte tabela:

<del><math>x</math></del>	$\theta$	0	$1/2$
1	0	0.10	
2	1		0.90

$$x=1 \rightarrow L_1 \text{ é maximizado em } \hat{\theta}(1) = 1/2$$

a maximizar depende de  $x$   $\nwarrow$   $x=2 \rightarrow \hat{\theta}(2)=0$

Exemplo: Distribuição normal com variação conhecida.

$x \sim N(\theta, \sigma^2)$  ;  $\sigma^2$  conhecida ; ( $\varphi$ : fdp da normal padrão. parâmetro de interesse =  $\theta$ ).

$x$  : valor observado

$$L_x(\theta) = \frac{1}{\sigma} \cdot \varphi\left(\frac{x-\theta}{\sigma}\right)$$

então  $\hat{\theta}(x) = \bar{x} \leftarrow$  estimador de Máximo Verossimilhança de  $\theta$  (MLE)

Em geral, se  $x_1, \dots, x_n$  é a.a  $N(\theta, \sigma^2)$   $\sigma^2$  conhecida

então, se  $x_1, \dots, x_n$  são os elementos observados,

$$\hat{\theta}(x_1, \dots, x_n) = \bar{x} \quad (\varphi(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}})$$

Da q'  $L_{(x_1, \dots, x_n)}^{(\theta)} = \prod_{i=1}^n L_{x_i}^{(\theta)} = \frac{1}{\sigma^n} \prod_{i=1}^n \varphi\left(\frac{\theta - x_i}{\sigma}\right)$

$$\frac{d}{d\theta} L_{\underline{x}}^{(\theta)} = 0 \quad \text{see } \frac{d}{d\theta} \left\{ \sum_{i=1}^n (\theta - x_i)^2 \right\} = 0 \quad \text{see } \sum_{i=1}^n (\theta - x_i) = 0$$

Verificar

se  $\hat{\theta}(x_1, \dots, x_n) = \bar{x} \rightarrow$  est suf

Exemplo (Tamanho populacional)  $x_1, \dots, x_n$  iid  $\mathcal{U}\{1, 2, \dots, \theta\}$

i.e.  $L_{\underline{x}}^{(\theta)} = \frac{1}{\theta^n} \prod_{i=1}^n \mathbb{1}_{\{x_i \leq \theta\}}$  i.e.  $L_{\underline{x}}^{(\theta)} = 0 \quad \forall \theta \in \{1, 2, \dots, x_{(n)}\}$

$$L_{\underline{x}}^{(\theta)} = \begin{cases} \frac{1}{x_{(n)}}^n & \text{se } \theta = x_{(n)} \\ \left[\frac{1}{x_{(n+1)}}\right]^n & \text{se } \theta = x_{(n+1)} \\ \vdots & \vdots \\ 0 & \text{se } \theta < x_{(n)} \end{cases}$$

ou seja o valor  $\hat{\theta}(\underline{x})$  que maximiza  $L_{\underline{x}}^{(\theta)}$

é  $\hat{\theta}(\underline{x}) = \underline{x_{(n)}}$   
 - MLE.  
 - est suf

•  $\hat{\theta}(\underline{x}) = x_{(n)}$  : estimativo ruim se  $\theta > x_{(n)}$

Verdadeiro.

$$\frac{1}{\sigma^n} \prod_{i=1}^n \psi\left(\frac{\theta - x_i}{\sigma}\right) = \frac{1}{\sigma^n} \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{(\theta - x_i)^2}{2\sigma^2}\right\}$$

$$= \frac{1}{\sigma^n} \cdot \frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2\right\}$$

$$\underbrace{\frac{d}{d\theta} \cdot}_{= \frac{1}{\sigma^n} \cdot \frac{1}{(2\pi)^{n/2}}} \frac{e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2}}{\cdot \left(-\frac{1}{\sigma^2}\right) \cdot \frac{d}{d\theta} \left\{\sum_{i=1}^n (x_i - \theta)^2\right\}}$$

$$= 0 \quad \text{see} \quad \frac{d}{d\theta} \left\{ \sum_{i=1}^n (\theta - x_i)^2 \right\} = 0$$

$$\sum_{i=1}^n 2(\theta - x_i) = 0.$$

$$n\hat{\theta} = \sum_{i=1}^n x_i$$

$$\hat{\theta} = \bar{x} \quad \checkmark$$

Contraste      Mínimo

Seja  $\ell_x(\theta) = \ln(L_x(\theta)) = \ln(p(x|\theta))$  ;  $p(\cdot|\theta) \in \mathcal{P} = \{P_\theta, \theta \in \mathbb{A}\}$

- MLE  $\hat{\theta}(x)$  minimiza  $-\ell_x(\theta)$ . ou seja minimiza  $-\ell_{\underline{x}}(\theta)$
- $\ln$  permite associar o critério de MV com função contraste.

Se  $x_1, \dots, x_n$  são iid  $p(\cdot|\theta)$  então

$$\ell_{\underline{x}}(\theta) = \ln(p(\underline{x}|\theta)) = \ln\left(\prod_{i=1}^n p(x_i|\theta)\right) = \sum_{i=1}^n \ln(p(x_i|\theta))$$

$$\ell_{\underline{x}}(\theta) = \sum_{i=1}^n \ell_{x_i}(\theta) \quad \underline{x} = (x_1, \dots, x_n)$$

contraste

definimos  $\mathcal{J}(x, \theta) = -\ell_{\underline{x}}(\theta)$  neste contexto  $\hat{\theta}(x)$  MLE

$\mathcal{J}$  minimiza  $-\ell_{\underline{x}}(\theta)$  oferece o menor contraste

$$\mathcal{D}(\theta_0, \theta) = -E_{\theta_0} \ln[p(x|\theta)]$$

$\theta_0$ : verdadeiro valor de  $\theta \in \mathbb{A}$

$\mathcal{D}$  é minimizado quando  $P_\theta = P_{\theta_0}$ . equivalentemente (exercício)

$$\mathcal{J}(\theta_0, \theta) - \mathcal{D}(\theta_0, \theta_0) > 0.$$

Nota q'  $\mathcal{D}(\theta_0, \theta_0) = -E_{\theta_0} \ln[p(x|\theta_0)]$  recebe o nome de entropia de  $x$  mediola de  $\theta_0$ .

máxima entropia ou divergência de Kullback Leibler entre  $p_0$  e  $p_1$

$$K(p_0, p_1) = -E_0 \left( \ln \left( \frac{p_1(x)}{p_0(x)} \right) \right)$$

$$= - \sum_x p_0(x) \cdot \ln \frac{p_1(x)}{p_0(x)}$$

se  $x$  assume valores discutos.

$$\text{ou } K(f_0, f_1) = -E_0 \left[ \ln \frac{f_1(x)}{f_0} \right]$$

$$= - \int_{\Omega} f_0(x) \cdot \ln \left( \frac{f_1(x)}{f_0} \right) dx$$

$X$  contínua.

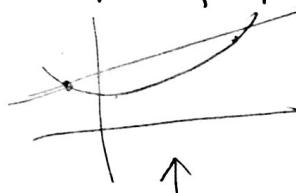
Para a definir  $K-L$  por convenção  $\frac{0}{0} = 0$ ;  $\frac{0}{0 \times \infty} = 0$

ou seja se  $p_0(x) = 0$  então  $\frac{P_1(x)}{P_0(x)} \ln \left( \frac{P_1(x)}{P_0(x)} \right) = 0$

$P_1(x) = 0$   $\frac{P_1(x)}{P_0(x)} \ln \left( \frac{P_1(x)}{P_0(x)} \right) = 0$

\*

Lema A entropia métrica  $K(p_0, p_1)$  é sempre bem definida e  $K(p_0, p_1) \geq 0$  com  $=$  se  $\{x; p_0(x) = p_1(x)\}$  possui probabilidade relativa a  $P_0$  e  $P_1$ .



dem.: (caso discreto)

Desigualdade de Jensen: se  $g: \mathbb{R} \rightarrow \mathbb{R}$  é convexa estrita e  $\neq$  v.a. tq  $E(z)$  é definida, então  $E(g(z)) \geq g(E(z))$  (Jensen)

Valendo a = se  $P(z=c)=1$ ;  $c = \text{cte}$

Assumimos  $g: X \sim P_0$ ; seja  $z = \frac{P_1(x)}{P_0(x)}$   $P_1$  e  $P_0$  massas.

$$g(z) = -\ln(z)$$

como  $g''(z) = \frac{-2}{z^2} > 0 \Rightarrow g$  é convexa estrita (exercício)

$$\text{Então } E(g(z)) = \sum_x p_0(x) \cdot \ln \left( \frac{p_1(x)}{p_0(x)} \right) \geq g(E(z)) = -\ln \left[ \sum_x p_0(x) \cdot \frac{p_1(x)}{p_0(x)} \right]$$

$\nearrow$   
 $x \sim P_0$

Assumindo  $\star$  para controlar a taxa de divergência, temos  $E(g(z)) \geq g(E(z)) \geq -\frac{\ln(\alpha)}{\alpha}$

Logo

$$E(g(z)) = -\underbrace{\sum_x p_0(x) \ln \left( \frac{p_1(x)}{p_0(x)} \right)}_{K(p_0, p_1)} = K(p_0, p_1) \geq 0.$$

$$K(p_0, p_1) = 0 \Leftrightarrow E(g(z)) = g(E(z)) \text{ se } P(z=c_0) = 1 \text{ se}$$

Nota  $p_1(x) > 0 \Rightarrow p_0(x) > 0$

$$P\left(\frac{p_1(x)}{p_0(x)} = c_0\right) = 1 \quad \text{se } P(p_1(x) = c_0 p_0(x)) = 1 \quad \text{então } 1 = \sum_x p_1(x) = \sum_x c_0 p_0(x) = c_0$$

$$\text{ie } p_0(x) = p_1(x) \forall x.$$

Nota. Suponha q'  $p_1(x) > 0 \not\Rightarrow p_0(x) > 0$

ie  $\exists x \in \mathbb{X} \mid p_1(x) > 0 \text{ e } p_0(x) = 0$  pelo desigualdade de Jensen  $\frac{p_1(x)}{p_0(x)} = c_0$  é falso  
impossível!

Exemplo Exemplo multinomial  $\theta_j = P(X=j) \quad j=1, \dots, k$

$x_1, \dots, x_n$  são de  $X \sim$  Multinomial  $k$  categorias

$$n_j = \sum_{i=1}^n \mathbf{1}_{(x_i=j)}$$

$$P(x, \theta) = \prod_{j=1}^k \theta_j^{n_j} \quad n_j \text{ valor assumido por } n_j \text{ em } x_1, \dots, x_n$$

$$L_x(\theta) = \ln \left( \prod_{j=1}^k \theta_j^{n_j} \right) = \sum_{j=1}^k \ln(\theta_j^{n_j}) = \sum_{j=1}^k n_j \ln(\theta_j)$$

$$\text{como } \sum_{j=1}^k \theta_j = 1 \Rightarrow \theta_k = 1 - \sum_{j=1}^{k-1} \theta_j$$

$$\frac{\partial \ell_x(\theta)}{\partial \theta_j} = \frac{\partial}{\partial \theta_j} \left\{ \sum_{s=1}^k n_s \ln(\theta_s) \right\} = \sum_{s=1}^k \frac{n_s}{\theta_s} \cdot \frac{\partial \theta_s}{\partial \theta_j} = 0 \quad j=1, \dots, k-1$$

equação de M V

$$\frac{\partial \theta_k}{\partial \theta_j} = -1 \quad \forall j \in \{1, \dots, k-1\}$$

Se  $j=1$

$$\begin{aligned} \frac{\partial \ell_x(\theta)}{\partial \theta_1} &= \frac{n_1}{\theta_1} \frac{\partial \theta_1}{\partial \theta_1} + \frac{n_2}{\theta_2} \frac{\partial \theta_2}{\partial \theta_1} + \dots + \frac{n_k}{\theta_k} \frac{\partial \theta_k}{\partial \theta_1} \\ &= \frac{n_1}{\theta_1} + (-1) \cdot \frac{n_k}{\theta_k} = 0 \quad \text{se } \frac{n_1}{\theta_1} = \frac{n_k}{\theta_k} \end{aligned}$$

$$\frac{n_1}{\theta_1} = \frac{n_k}{1 - \sum_{j=1}^{k-1} \theta_j} \quad \text{ie} \quad \frac{\theta_1}{n_1} = \frac{1 - \sum_{j=1}^{k-1} \theta_j}{n_k} = \frac{1 - \theta_1 - \sum_{j=2}^{k-1} \theta_j}{n_k}$$

$$\frac{\theta_1}{n_1} + \frac{\theta_1}{n_k} = \frac{1 - \sum_{j=2}^{k-1} \theta_j}{n_k} \quad \text{se } \left( \frac{1}{n_1} + \frac{1}{n_k} \right) \theta_1 = \frac{1 - \sum_{j=2}^{k-1} \theta_j}{n_k}$$

$$\text{ie } \forall j \in \{1, \dots, k-1\} \quad \left( \frac{1}{n_j} + \frac{1}{n_k} \right) \theta_j = \frac{1 - \sum_{s=1}^{k-1} \theta_s}{n_k} \quad \text{Sistema de equações.}$$

$k=3$

$$\left( \frac{1}{n_j} + \frac{1}{n_3} \right) \theta_j = \frac{1 - \sum_{s=1}^2 \theta_s}{n_3} \quad j=1, 2 \rightarrow \begin{cases} \left( \frac{1}{n_1} + \frac{1}{n_3} \right) \theta_1 = \frac{1 - \theta_2}{n_3} \\ \left( \frac{1}{n_2} + \frac{1}{n_3} \right) \theta_2 = \frac{1 - \theta_1}{n_3} \end{cases}$$

$$\underbrace{\frac{(n_1+n_3)}{n_1 \cdot n_3} \cdot \theta_1}_{\text{a}} = \frac{1-\theta_2}{n_3} \quad \text{et} \quad \underbrace{\frac{n_2+n_3}{n_2 \cdot n_3} \cdot \theta_2}_{\text{b}} = \frac{1-\theta_1}{n_3}$$

$$\underbrace{\frac{n_1+n_3}{n_1} \cdot \theta_1}_{\text{a}} = 1 - \theta_2 \quad \text{et} \quad \underbrace{\frac{n_2+n_3}{n_2} \cdot \theta_2}_{\text{b}} = 1 - \theta_1$$

$$b \Rightarrow \theta_2 = (1-\theta_1) \cdot \frac{n_2}{n_2+n_3} = \frac{n_2}{n_2+n_3} - \theta_1 \cdot \frac{n_2}{n_2+n_3} \quad \text{en a}$$

$$\underbrace{\frac{(n_1+n_3)}{n_1} \cdot \theta_1}_{\text{a}} = 1 - \frac{n_2}{n_2+n_3} + \theta_1 \cdot \frac{n_2}{n_2+n_3} \Rightarrow \left[ \frac{(n_1+n_3)}{n_1} - \frac{n_2}{n_2+n_3} \right] \theta_1 = 1 - \frac{n_2}{n_2+n_3}$$

$$\text{see } \left\{ \frac{(n_1+n_3)(n_2+n_3) - n_2 \cdot n_1}{n_1 \cdot (n_2+n_3)} \right\} \theta_1 = \frac{y_2 + y_3 - y_1}{n_2+n_3} \quad \text{see}$$

$$\frac{(n_1+n_3)(n_2+n_3) - n_2 \cdot n_1}{n_1} \cdot \theta_1 = n_3$$

$$\hat{\theta}_1 = \frac{n_3 \cdot n_1}{(n_1+n_3)(n_2+n_3) - n_1 \cdot n_2} = \frac{n_1 \cdot n_3}{n_1 y_2 + n_1 y_3 + n_2 y_3 + n_3 y_3 - n_1 n_2} = \frac{n_1}{n_1 + n_2 + n_3}$$

$$\hat{\theta}_1 = \frac{n_1}{n} \quad \text{et} \quad \hat{\theta}_2 = \frac{n_2}{n} \quad \checkmark$$

Exercice demonstre q'  $(\hat{\theta}_1, \hat{\theta}_2)$  maximise  $\mathcal{L}_{\underline{x}}(\theta)$

$$= \ln \left( \prod_{j=1}^k \theta_j^{n_j} \right)$$

Quem é  $D(\theta_0, \theta) - D(\theta_0, \theta_0) = ?$

$$D(\theta_0, \theta) = -E_{\theta_0} [\ln p(x, \theta)]$$

entropia de medida  $P_{\theta_0}$ .

$$\begin{aligned} D(\theta_0, \theta) - \overbrace{D(\theta_0, \theta_0)} &= -E_{\theta_0} [\ln p(x, \theta)] + E_{\theta_0} [\ln p(x, \theta_0)] \\ &= - \left\{ E_{\theta_0} [\ln p(x, \theta)] - E_{\theta_0} [\ln p(x, \theta_0)] \right\} \\ &= -E_{\theta_0} \left\{ \ln p(x, \theta) - \ln p(x, \theta_0) \right\} \\ &= -E_{\theta_0} \left\{ \ln \left( \frac{p(x, \theta)}{p(x, \theta_0)} \right) \right\} = K(P_{\theta_0}, P_{\theta}). \end{aligned}$$

= divergência K-L entre  
 $P_{\theta_0}$  e  $P_{\theta}$ .

Ou seja, se achamos  $\theta$  q' minimize  $K(P_{\theta_0}, P_{\theta})$ , achamos  $\theta$  q' se  
 aproxima a  $\theta_0$  no sentido da medida de K-L.