

Exemplo 6.3.1 Supondo  $x_1, x_2, \dots, x_n$  iid ( $x \sim \text{Gomo}(\alpha, \beta)$ )

$$p(x; \theta) = \beta^\alpha x^{\alpha-1} \exp(-\beta x) / \Gamma(\alpha) \quad ; x > 0; \alpha > 0, \beta > 0$$

mostramos  $\hat{\theta} = (\hat{\alpha}, \hat{\beta})$  é mas  $\hat{\theta}$  não tem solução <sup>im</sup> explícita.

Assim se fizemos  $\lambda(x) = \frac{\sup(p(x, \theta) : \theta \in \Theta)}{\inf(p(x, \theta) : \theta \in \Theta)} = \star$

testando  $H : \theta \in \Theta_0$  vs  $H_1 : \theta \in \Theta_1$ ,  $\Theta_1 = \Theta - \Theta_0$ .

que apresentam soletra dívidíveis mas estatísticas  $t \in \mathbb{F}$  no geral

não pode ser aplicada aqui. VD se  $\hat{p}'(x, \hat{\theta}) = \prod_{i=1}^n p(x_i, \hat{\theta})$  não

esta disponível nesse modelo. Sufira por exemplo  $\hat{p}'$  designado testa

$H : \alpha = 1$  vs  $H_1 : \alpha \neq 1$

exponencial

neste caso  $\hat{\beta}(\text{EMV}) = \frac{1}{x} \quad ; \quad p(x; (1, \frac{1}{x}))$  é o denominador em  $\star$

Mesmo assim não podemos derivar os valores críticos de  $\lambda(x)$  de forma analítica.

Usaremos a aproximação:

$$\underbrace{2 \log \lambda(x)}_{\text{do tipo}} \xrightarrow{L} \chi_d^2$$

Exemplo 6.3.2 Modelos lineares normais de Jauáneos conteados

$$Y_1, \dots, Y_n \quad Y_i \sim N(\mu_i, \sigma^2) \quad \sigma^2 \text{ constante.}$$

exercícios

Exemplos 6.3.2 - 6.3.3

Teorema 6.3.1. Supondo q' certas condições de regularidade sejam válidas (pag 384) na função  $f(x|\theta) = \log p(x|\theta)$ , então temos a hipótese

$$H: \theta = \theta_0, \quad 2 \log \lambda(x) = 2 \left[ \ln(\hat{\theta}_n) - \ln(\theta_0) \right] \xrightarrow{L} \chi^2_r$$

Sendo  $x_1, \dots, x_n$  aa daa daa  $p(x|\theta)$ ;  $x \in \mathbb{X} \subset \mathbb{R}^S$ ;  $\theta \in \Theta \subseteq \mathbb{R}^r$ .

$$l_n(\theta) = \sum_{i=1}^n \log p(x_i|\theta).$$

Def:  $\hat{\theta}_n$  e' o EMV ie.  $D_\theta l_n(\theta) = 0$ ;  $D_\theta$ : derivada de  $l_n$  em relação ao  $\theta$ .

Consideremos: uma exp. de  $l_n(\theta)$  por volta de  $\hat{\theta}_n$  e anotado no  $\theta = \theta_0$ .

$$2 \left[ \ln(\hat{\theta}_n) - \ln(\theta_0) \right] = n (\hat{\theta}_n - \theta_0)^T I_n(\theta_n^*) (\hat{\theta}_n - \theta_0).$$

↓

Verifique exercícios

Prova alguma valor  $\theta_n^*$  tal que  $|\theta_n^* - \hat{\theta}_n| \leq |\hat{\theta}_n - \theta_0|$  e então

$$I_n(\theta) = \left\| -\frac{1}{n} \sum_{i=1}^n \frac{\partial}{\partial \theta_k} \frac{\partial}{\partial \theta_j} \log p(x_i, \theta) \right\|_{r \times r}$$

por normalidade assintótica, resulta  $\sqrt{n} (\hat{\theta}_n - \theta_0) \xrightarrow{L} N(0, I^{-1}(\theta_0))$

(veja teor 6.2.2)

método de inf de Fisher

Alem disso

$$|\theta_n^* - \theta_0| \leq |\theta_n^* - \hat{\theta}_n| + |\hat{\theta}_n - \theta_0| \leq 2 |\hat{\theta}_n - \theta_0|.$$

pelos condicões de regularidade A<sub>3</sub> e A<sub>4</sub>, especificamente pelo consisténcia de A<sub>4</sub> resulta  $I_n(\theta_n^*) \xrightarrow{P} E(I_n(\theta_0)) = I(\theta_0)$  (Exercício)

Logo:  $2[\ln(\hat{\theta}_n) - \ln(\theta_0)] \xrightarrow{d} \sqrt{I(\theta_0)} V, V \sim N(0, I'(\theta_0))$

Pelo resultado B.6.2 (pág 508)  $\Rightarrow \sqrt{I(\theta_0)} V \sim \chi_r^2$  \*

exercício

Consequência do Teorema a) H.  $\theta = \theta_0$  é rejeitado se  $2 \log \lambda(x) \geq \underline{x}_{r(1-\alpha)}$

$1-\alpha$   
quantile

b) região de confiança:  $\left\{ \theta_0 : 2[\ln(\hat{\theta}_n) - \ln(\theta_0)] \leq \underline{x}_{r(1-\alpha)} \right\}$

(1-α)

dados

$$\left\{ \theta_0 : \hat{\theta}_0 = \left\{ \theta \in \Theta : \theta_j = \theta_{0,j}, j = q+1, \dots, r \right\} \right\}$$

Hipótese:  $H: \theta \in \Theta_0 \subseteq \Theta; \Theta_0 = \left\{ \theta \in \Theta : \theta_j = \theta_{0,j}, j = q+1, \dots, r \right\}$   
o parâmetro  $\theta = (\theta^{(1)}, \theta^{(2)})$  onde  $\theta^{(1)} = (\theta_1, \dots, \theta_q)$ ,  $\theta^{(2)} = (\theta_{q+1}, \dots, \theta_r)^T$

Teorema 6.3.2: Suponha q' valem as condições de regularidade A<sub>0</sub>-A<sub>6</sub>

na função  $g(x|\theta) = \log p(x|\theta)$ ,  $\theta \in \Theta$ . Seja  $P_0$  o modelo

$\{P_\theta, \theta \in \Theta\}$  levando em conta as reparametrizações  $\theta^{(1)} = (\theta_1, \dots, \theta_q)$

$\hat{\theta}_0^{(1)}$  é o EMV de  $\theta^{(1)}$  em H.  $\hat{\theta}_0^{(1)}$  verifica a condição A<sub>6</sub> para  $P_0$ .

Seja  $\hat{\theta}_{0,n}^T = (\hat{\theta}_0^{(1)}, \hat{\theta}_0^{(2)})$ . Então em H:  $\theta \in \Theta_0 \subseteq \Theta$

$\Theta_0 = \left\{ \theta \in \Theta : \theta_j = \theta_{0,j}, j = q+1, \dots, r \right\}$

$$2 \log \lambda(x) = 2[\ln(\hat{\theta}_n) - \ln(\hat{\theta}_{0,n})] \xrightarrow{d} \chi_{r-q}^2$$

Note que  $\Theta_0$  é um conjunto de valores de  $\theta \in \Theta \subseteq \mathbb{R}^r$  que fixa os valores de  $\theta_j$ ,  $j = q+1, \dots, r$ . Ou seja

$$\Theta_0 = \left\{ \theta \in \Theta, \theta_j = \theta_{0,j} \text{ } i, j = q+1, \dots, r \right\}$$

$$\begin{aligned} \theta &= (\theta^{(1)}, \theta^{(2)}), \theta^{(1)} = (\theta_1, \dots, \theta_q)^T \\ \downarrow \text{definição} & \\ \theta^{(2)} &= (\theta_{q+1}, \dots, \theta_r)^T \\ \theta_j &= (\theta_{0,q+1}, \dots, \theta_{0,r})^T \end{aligned}$$

Notas : situações de casos  $\textcircled{H}_0$ : com efeitos

Valores nas coordenadas de  $\theta$  veja exemplo 6.3.2  
6.3.3

Testes associados: (i) estatística de Wald

Brinque o Teorema 6.2.2, em particular: sob condições  $A_0 - A_5$  em  $f(x; \theta) = \log(P(x; \theta))$  se  $\hat{\theta}_n$  é o estimador de Máxima Verossimilhança  $\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, I^{-1}(\theta))$   $\textcircled{*}$

$\theta$ : r-dim.

o resultado B.7.1(a) garante que se em  $I(\theta)$  esamos o EHV  $\hat{\theta}_n$ , temos  $I(\hat{\theta}_n) \xrightarrow[n \rightarrow \infty]{\mathcal{P}} I(\theta)$   $\textcircled{*}$

Logo, Slutsky permite estabelecer:

$$n(\hat{\theta}_n - \theta)^T I(\hat{\theta}_n)(\hat{\theta}_n - \theta) \xrightarrow{\mathcal{D}} \sqrt{T} I(\theta) \cdot V$$

$$\text{onde } V \text{ é } N_r(0, I^{-1}(\theta))$$

já o corolário B.6.2 garante que  $\sqrt{T} I(\theta) V \sim \chi^2_r$

Assim é possível definir a estatística de Wald

em  $\theta = \theta_0$

$$W_n(\theta_0) = n(\hat{\theta}_n - \theta_0)^T I(\theta_0)(\hat{\theta}_n - \theta_0)$$

Procedimento de Wald de  $H_0: \theta = \theta_0$  vs  $H_1: \theta \neq \theta_0$

rejetamos  $H_0$  se  $W_n(\theta_0) > \chi^2_{r, (1-\alpha)}$   $\uparrow$  quantil  $1-\alpha$  da uma dist  $\chi^2_r$ .

Notas

- ① para estimar  $\mathcal{I}(\theta_0)$  podemos usar  $\mathcal{I}(\hat{\theta}_n)$   
outros quais? justifique!
- ② Existem Variantes do teste de Wald no marco do Teorema 6.3.2 onde devemos considerar uma alteração nos graus de liberdade da distribuição  $\chi^2$ .  
Vejam Teorema 6.3.4.
- ③ Região de confiança:  $\{\theta : \mathcal{V}_n(\theta) \leq \chi_{r, 1-\alpha}^2\}$ .

Um procedimento permente baseado na lei limite da estatística de Rao:

Considera a quantidade  $\mathcal{Z}_n = \frac{1}{n} \mathcal{J} l_n(\theta)$  onde

$l_n(\cdot) = \sum_{i=1}^n \log(P(x_i, \cdot))$  é possível provar que

$$\sqrt{n} \cdot \mathcal{Z}_n(\theta_0) \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, \mathcal{I}(\theta_0)).$$

pois este fato decorre do Teorema central do limite aplicado à média  $\mathcal{Z}_n$ :  $E(\frac{\partial \log(P(x_i, \theta))}{\partial \theta}) = 0$  ✓  
 $\text{Var}(\frac{\partial \log(P(x_i, \theta))}{\partial \theta}) = \mathcal{I}(\theta)$ . ✓

Vejam detalhes no módulo 9.

- 
- ① ① é válido pois  $\mathcal{I}(\hat{\theta}_n)$  é estimativa consistente de  $\mathcal{I}(\theta_0)$   
outras estimativas consistentes são a)  $-\frac{1}{n} \mathcal{J}^2 l_n(\hat{\theta}_n)$   
ou b)  $-\frac{1}{n} \mathcal{J}^2 l_n(\theta_0)$  onde  $l_n(\cdot) = \sum_{i=1}^n \log(P(x_i, \cdot))$ .  
a) pode ser mais simples.

$$\sqrt{n} \hat{\theta}_n(\theta_0) \xrightarrow{d} N(0, I(\theta_0)) ; \hat{\theta}_n = \frac{1}{n} D\ell_n(\theta_0)$$

pelo corolário 3.6.2 sob a hipótese  $H_0: \theta = \theta_0$ .

e quando  $n \rightarrow \infty$ ,

$$n \hat{\theta}_n^T(\theta_0) I^{-1}(\theta_0) \hat{\theta}_n(\theta_0) \xrightarrow[n \rightarrow \infty]{d} \chi_r^2 ; \theta_0 \in \mathbb{R}^r$$

A estatística

$$Q_n(\theta_0) = n \hat{\theta}_n^T(\theta_0) I^{-1}(\theta_0) \hat{\theta}_n(\theta_0)$$

e' a estatística de Rao. (ou Score de Rao).

Logo,  $H_0$  e' rejeitado se  $Q_n(\theta_0) > \chi_{r; 1-\alpha}^2$

Rao score test

Exercícios Teoremas 6.3.4 e 6.3.5 aplicar no modelo Normal.