

# Estatística bayesiana

## Distribuições *a priori* não informativas

José Passos

ISEG-ULisboa

2 de Dezembro de 2019



# Tabela de conteúdos

- 1 Introdução
- 2 Abordagem de Laplace
- 3 Abordagem de Jeffreys
- 4 Outras abordagens
- 5 Bibliografia

# Introdução

- Uma das características da inferência bayesiana é a possibilidade de expressar a informação sobre os parâmetros,  $\theta$ , por intermédio de uma distribuição de probabilidade
- Vamos estudar a situação de ausência de informação *a priori* sobre os parâmetros

# Abordagem de Laplace

- Laplace foi o primeiro a utilizar distribuições *a priori* não informativas para os parâmetros
- Estas distribuições baseiam-se no princípio da razão insuficiente de Bayes-Laplace que assumem a equiprobabilidade dos acontecimentos elementares na ausência de informação
- Um exemplo clássico é a população de Bernoulli de parâmetro  $\theta$
- De acordo com o princípio da razão insuficiente a distribuição *a priori* não informativa é uniforme,  $g(\theta) = I_{(0,1)}(\theta)$ , com distribuição *a posteriori*,

$$h(\theta|x) \propto g(\theta) L(\theta|x) = \theta^x (1 - \theta)^{1-x} I_{(0,1)}(\theta)$$

## Problemas da abordagem de Laplace

- Se  $\Theta$  não é compacto,  $g(\theta) \propto k$  é imprópria, i.é.,  
 $\int g(\theta)d\theta = \infty$
- O princípio de acontecimentos equiprováveis não é coerente sob partições de  $\Theta$ :
  - se  $\Theta = \{\theta_1, \theta_2\}$  o princípio da razão insuficiente conduz a  $g(\theta_1) = g(\theta_2) = 1/2$ ;
  - Se  $\Theta = \{\theta_1, w_1, w_2\}$  tem-se de acordo com o mesmo princípio  $g(\theta_1) = 1/3$ , contrariando a 1ª condição.
- A distribuição *a priori* não é invariante sobre parametrizações de  $\Theta$ : na parametrização  $\eta = \tau(\theta)$ , transformação biunívoca de  $\theta$ , em geral,  
 $g^*(\eta) \propto |d\tau^{-1}(\eta)/d\eta|$  não é constante

## Problemas da abordagem de Laplace

- Exemplo: numa população de Bernoulli,  $X \sim Be(\theta)$ , tem-se  $g(\theta) = I_{(0,1)}(\theta)$ . Considerando a parametrização,

$$\eta = \tau(\theta) = \frac{\theta}{1 - \theta}$$

a distribuição *a priori* na nova parametrização,  $g^*(\eta)$ , é dada por,

$$g^*(\eta) = g\left(\tau^{-1}(\eta)\right) \left| \frac{d\tau^{-1}(\eta)}{d\eta} \right| = \frac{1}{(1 + \eta)^2}$$

que não é constante em  $\eta$

## 1ª e 2ª regra de Jeffreys

- Jeffreys procura resolver alguns dos problemas associados à abordagem de Bayes- Laplace
- Propõe duas regras: uma para parâmetros de localização e outra para parâmetros de escala, com propriedades de invariância para certo tipo de transformações
- **1ª regra (parâmetros de localização):** se  $\Theta = \{\theta : -\infty < \theta < \infty\}$  Jeffreys propõe  $g(\theta) \propto k$ 
  - $g(\theta) \propto k$  é imprópria
  - $g(\theta) \propto k$  é invariante a parametrizações do tipo  $\eta = a + b\theta$  pois ainda se tem  $g^*(\eta) \propto k$

# 1ª e 2ª regra de Jeffreys

- **2ª regra (parâmetros de escala):** se  $\Theta = \{\theta : 0 < \theta < \infty\}$   
Jeffreys propõe  $g(\theta) \propto 1/\theta$ 
  - $g(\theta) \propto 1/\theta$  é imprópria
  - $g(\theta) \propto 1/\theta$  é invariante a parametrizações do tipo  $\eta = \theta^n$   
pois ainda se tem  $g^*(\eta) \propto 1/\eta$



## Abordagem geral de Jeffreys

- Jeffreys fundamenta as duas regras num tratamento mais geral utilizando a medida de informação de Fisher sobre  $\theta$  contida na amostra.
- Jeffreys explora as propriedades de invariância da medida de informação de Fisher propondo como distribuição *a priori* não informativa,

$$g(\theta) \propto I(\theta)^{1/2}$$

- A aplicação das duas regras ou da regra geral conduzem à mesma distribuição *a priori*

## Abordagem geral de Jeffreys

- Se  $\theta$  é um vector com  $k$  parâmetros Jeffreys propõe como distribuição *a priori* não informativa,

$$g(\theta) \propto [\det I(\theta)]^{1/2}$$

- No caso  $k$ -paramétrico a aplicação das duas regras ou da regra geral não conduzem, em geral, à mesma distribuição *a priori*

## Abordagem geral de Jeffreys

**Exemplo:**  $X \sim N(\mu, \sigma)$  e considere uma amostra casual de dimensão  $n$

- regra geral:

$$I(\mu, \sigma) = \begin{bmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{2n}{\sigma^2} \end{bmatrix}$$

com distribuição *a priori*,

$$g(\mu, \sigma) \propto |I(\mu, \sigma)|^{1/2} = \frac{n\sqrt{2}}{\sigma^2} \propto \frac{1}{\sigma^2}$$

# Abordagem geral de Jeffreys

- 1ª e 2ª regra: supondo independência de  $\mu$  e  $\sigma$  temos,

$$g(\mu, \sigma) = g(\mu)g(\sigma)$$

sendo  $\mu$  um parâmetro de localização,  $g(\mu) \propto k$ , e sendo  $\sigma$  uma parâmetro de escala,  $g(\sigma) \propto 1/\sigma$ , tem-se a distribuição *a priori*

$$g(\mu, \sigma) = g(\mu)g(\sigma) \propto \frac{k}{\sigma} \propto \frac{1}{\sigma}$$

# Outras abordagens

- Box-Tiao
- Entropia máxima (Zellner)
- Berger-Bernardo

# Bibliografia

- Paulino; Turkman; Murteira; Silva (2018), *Estatística bayesiana*, Fundação Calouste Gulbenkian, 2<sup>a</sup> Edição.