

# Inferência Bayesiana: Modelo Paramétrico Lognormal

## Análise de Sobrevivência

Guilherme Augusto Veloso


Prof. Dr. Enrico Antônio Colosimo - UFMG

Maio 2017

- 1 Introdução
- 2 Inferência Bayesiana
  - Probabilidade Subjetiva
  - Distribuição *a priori*
  - Função de Verossimilhança
  - Distribuição *a posteriori*
  - Teorema de Bayes
- 3 Modelo Paramétrico Exponencial
- 4 Modelo Paramétrico Lognormal
- 5 Referências

## VERTENTES DA INFERÊNCIA ESTATÍSTICA

INFERÊNCIA  
CLÁSSICA



INFERÊNCIA  
BAYESIANA



## Quadro Comparativo

<b>INFERÊNCIA CLÁSSICA</b>	<b>INFERÊNCIA BAYESIANA</b>
É associada à interpretação frequentista de probabilidade	A probabilidade representa uma abordagem subjetiva
Os parâmetros são considerados quantidades fixas	Os parâmetros são considerados quantidades aleatórias
A Teoria de Verossimilhança desempenha papel de destaque	Atualização da informação subjetiva via Teorema de Bayes
Intervalos de Confiança	Intervalos de Credibilidade


# Probabilidade Subjetiva

## Situação-problema:

- Qual a proporção atual de crianças com excesso de peso em Belo Horizonte?
- Vamos denominar essa proporção de  $\theta$ .
- $\theta$  por ser uma proporção está entre 0 e 1. É provável que esteja próximo de 0? Próximo de 1? E de 0,25?
- Podemos construir uma distribuição de probabilidades que represente o nosso conhecimento.

# Distribuição *a priori*

- A distribuição *a priori*  $\pi(\theta)$  fornece a probabilidade dos diferentes valores possíveis da quantidade de interesse **ANTES** dos dados serem considerados.
- A distribuição *a priori* pode ser ampla, plana, uniforme (*priori* não informativa), ou pode se concentrada com um ápice se possuímos mais informação (*priori* informativa).




# Função de Verossimilhança

- A Função de Verossimilhança  $L(y|\theta)$  fornece a probabilidade de obter os dados, considerando diferentes valores possíveis da quantidade desconhecida de interesse  $\theta$ .
- É calculada usando um modelo estatístico que representa o processo que produziu os dados.
- Conecta os parâmetros do modelo aos dados.

# Distribuição *a posteriori*

- A distribuição *a posteriori*  $\pi(\theta|y)$  fornece a probabilidade dos diferentes valores possíveis da quantidade de interesse **DEPOIS** de considerar os dados.
- Essa distribuição é combinação da *priori* (o que sabemos antes) com a Verossimilhança (o que os dados nos disseram).





# Teorema de Bayes

- A informação contida na distribuição *a priori*  $\pi(\theta)$  é então atualizada, através da informação dos dados contida em  $L(y|\theta)$ , via teorema de Bayes, levando à distribuição *a posteriori* de  $\theta$ , dada por:

$$\pi(\theta|y) = \frac{L(y|\theta) \cdot \pi(\theta)}{\int_{\Theta} L(y|\theta) \cdot \pi(\theta) d\theta}.$$

- Comumente escrevemos:  $\pi(\theta|y) \propto L(y|\theta) \cdot \pi(\theta)$ .

# Modelo Paramétrico Exponencial

## Função de Verossimilhança:

Suponha que os tempos de sobrevivência  $\mathbf{t} = (t_1, t_2, \dots, t_n)'$  possuem distribuição  $Exp(\lambda)$ , de modo que:

$$f(t_i|\lambda) = \lambda \exp(-\lambda t_i), \text{ com } i = 1, 2, \dots, n.$$

- A Função de Sobrevivência é:  $S(t_i|\lambda) = \exp(-\lambda t_i)$ .
- Seja  $D = (n, \mathbf{t}, \delta)$ . A Função de Verossimilhança é:

$$L(D|\lambda) = \prod_{i=1}^n f(t_i|\lambda)^{\delta_i} S(t_i|\lambda)^{(1-\delta_i)} = \lambda^{\sum_{i=1}^n \delta_i} \exp\left(-\lambda \sum_{i=1}^n t_i\right).$$

# Modelo Paramétrico Exponencial

## Distribuições *a priori* e *a posteriori*:

- A distribuição *a priori* de  $\lambda$  é uma  $Gama(\alpha, \beta)$ :

$$\pi(\lambda|\alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \lambda^{\alpha-1} \exp(-\beta\lambda).$$

- Desse modo, temos que a distribuição *a posteriori* de  $\lambda$  é:

$$\begin{aligned} \pi(\lambda|D) &\propto L(D|\lambda) \cdot \pi(\lambda|\alpha, \beta) \\ &\propto \left[ \lambda^{\sum_{i=1}^n \delta_i} \exp\left(-\lambda \sum_{i=1}^n t_i\right) \right] \cdot [\lambda^{\alpha-1} \exp(-\beta\lambda)] \\ &= \lambda^{\alpha + \sum_{i=1}^n \delta_i - 1} \exp\left[-\left(\beta + \sum_{i=1}^n t_i\right) \lambda\right]. \end{aligned}$$

# Modelo Paramétrico Exponencial

## Distribuição *a posteriori* - Interpretação:

■ Desse modo,  $\pi(\lambda|D) \sim \text{Gama} \left( \alpha + \sum_{i=1}^n \delta_i; \beta + \sum_{i=1}^n t_i \right)$

■ 
$$E(\lambda|D) = \frac{\alpha + \sum_{i=1}^n \delta_i}{\beta + \sum_{i=1}^n t_i}$$

■ 
$$V(\lambda|D) = \frac{\alpha + \sum_{i=1}^n \delta_i}{\left( \beta + \sum_{i=1}^n t_i \right)^2}$$

# Exemplo: Lâmpadas de Projetores LCD

- A falha mais comum desses projetores é na lâmpada.
- Um fabricante alega que os usuários podem esperar cerca de 1500 horas de projeção em cada lâmpada usada em condições normais de operação.
- Podemos usar essa informação para construir a distribuição *a priori* para  $\lambda$ ?



# Exemplo: Lâmpadas de Projetores LCD

## Construção da Distribuição *a priori*:

- Seja  $(\lambda|\alpha, \beta) \sim \text{Gama}(\alpha, \beta)$ .
- Se  $\kappa = \frac{1}{\lambda}$ , então  $(\kappa|\alpha, \beta) \sim \text{Gama Inversa}(\alpha, \beta)$ .
- Considerando as expressões para a média e a variância da distribuição Gama Inversa, tem-se que:

$$\begin{cases} \frac{\beta}{\alpha-1} = 1500 \\ \sqrt{\frac{\beta^2}{(\alpha-1)^2(\alpha-2)}} = 2000 \end{cases} \Rightarrow \alpha = 2,5 \text{ e } \beta = 2350.$$

- Desse modo,  $\pi(\lambda|\alpha, \beta) \sim \text{Gama}(2,5; 2350)$ .

## Exemplo: Lâmpadas de Projetores LCD

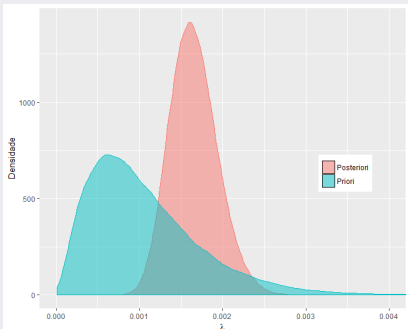
- Foram registradas as horas de projeção até a falha de lâmpadas idênticas que estavam em 31 projetores LCD.

### Construção da Distribuição *a posteriori*:


- $\sum_{i=1}^n t_i = 17907$  e  $\sum_{i=1}^n \delta_i = n = 31$
- $\pi(\lambda|D) \sim \text{Gama}\left(\alpha + \sum_{i=1}^n \delta_i; \beta + \sum_{i=1}^n t_i\right)$   
 $\sim \text{Gama}(2, 5 + 31; 2350 + 17907)$   
 $\sim \text{Gama}(33, 5; 20257)$

# Exemplo: Lâmpadas de Projetores LCD

## Distribuições *a priori* e *a posteriori* de $\lambda$



## Distribuição *a posteriori* de $\frac{1}{\lambda}$





# Exemplo: Lâmpadas de Projetores LCD

## Estimativas *a posteriori* para quantidades de interesse:

Parâmetro  $\lambda$ :

- $\hat{\lambda}_B = E(\lambda|D) = \frac{33.5}{20257} = 0.001653$
- $\hat{\lambda}_{MV} = \frac{1}{\bar{t}} = \frac{1}{577.6452} = 0.001731$
- Intervalo de Credibilidade de 90% para  $\lambda$ : [0, 00121; 0, 00214]

Tempo médio até a falha ( $\frac{1}{\lambda} = \kappa$ ):

- $\hat{\kappa} = 623,44$
- Intervalo de Credibilidade de 90% para  $\kappa$  : [465, 17; 824, 76]

# Modelo Paramétrico Lognormal

## Função de Verossimilhança:

Suponha que os tempos de sobrevivência  $\mathbf{t} = (t_1, t_2, \dots, t_n)'$  possuem distribuição  $LN(\mu; \sigma^2)$ , de modo que:

$$f(t_i|\mu, \sigma^2) = (2\pi)^{-1/2} (t_i\sigma)^{-1} \exp \left[ -\frac{1}{2\sigma^2} (\log(t_i) - \mu)^2 \right].$$

- A Função de Sobrevivência é:  $s(t_i|\mu, \sigma^2) = 1 - \Phi \left( \frac{\log(t_i) - \mu}{\sigma} \right)$ .
- Seja  $D = (n, \mathbf{t}, \delta)$ . A Função de Verossimilhança é:

$$\begin{aligned} L(D|\mu, \sigma^2) &= \prod_{i=1}^n f(t_i|\mu, \sigma^2)^{\delta_i} S(t_i|\mu, \sigma^2)^{(1-\delta_i)} \\ &= (2\pi\sigma^2)^{-\frac{\sum_{i=1}^n \delta_i}{2}} \exp \left[ -\frac{1}{2\sigma^2} \sum_{i=1}^n \delta_i (\log(t_i) - \mu)^2 \right] \times \prod_{i=1}^n t_i^{-\delta_i} \left[ 1 - \Phi \left( \frac{\log(t_i) - \mu}{\sigma} \right) \right]^{1-\delta_i}. \end{aligned}$$

# Modelo Paramétrico Lognormal

## Distribuições *a priori*:

- Seja  $\tau = 1/\sigma^2$ .
- Não existe *priori* conjugada para  $(\mu, \tau)$  quando ambos são quantidades desconhecidas.
- Seja  $\pi(\mu, \tau) = \pi(\mu|\tau) \cdot \pi(\tau)$ .
- Nesse caso, uma típica escolha de *priori* conjunta é:
  - $\pi(\mu|\tau) \sim N\left(\mu_0, \frac{1}{\tau\tau_0}\right)$ ;
  - $\pi(\tau) \sim \text{Gama}\left(\frac{\alpha}{2}, \frac{\beta}{2}\right)$ .

# Modelo Paramétrico Lognormal

## Distribuição *a posteriori*:

$$\begin{aligned}\pi(\mu, \tau | D) &\propto L(D | \mu, \tau) \cdot \pi(\mu, \tau | \mu_0, \tau_0, \alpha, \beta) \\ &\propto L(D | \mu, \tau) \cdot \pi(\mu | \tau, \mu_0, \tau_0) \cdot \pi(\tau | \alpha, \beta) \\ &\propto \tau^{\frac{\alpha_0 + \sum_{i=1}^n \delta_i + 1}{2} - 1} \exp \left\{ -\frac{\tau}{2} \left[ \sum_{i=1}^n \delta_i (\log(t_i) - \mu)^2 + \tau_0 (\mu - \mu_0)^2 + \beta \right] \right\} \\ &\times \prod_{i=1}^n t_i^{-\delta_i} \left[ 1 - \Phi \left( \tau^{\frac{1}{2}} (\log(t_i) - \mu) \right) \right]^{1 - \delta_i}\end{aligned}$$

# Amostrador de Gibbs

## Algoritmo:

Seja  $(\mu, \tau)$  os parâmetros de interesse e  $\pi(\mu, \tau|D)$  a distribuição *a posteriori*. Segue o esquema básico do Amostrador de Gibbs:

**PASSO 0:** Escolha valores iniciais arbitrários para  $(\mu^{(0)}, \tau^{(0)})$ .

**PASSO 1:** Gere  $(\mu^{(i+1)}, \tau^{(i+1)})$  da seguinte maneira:

- Gere  $\mu^{(i+1)} \sim \pi(\mu|\tau^{(i)}, D)$ ;
- Gere  $\tau^{(i+1)} \sim \pi(\tau|\mu^{(i+1)}, D)$ .

**PASSO 2:** Determine  $i = i + 1$  e volte ao Passo 1 até que  $i = M$ , com  $M$  (Número de iterações) pré-especificado.

# Exemplo: Dados de Câncer de Bexiga

## Distribuições *a priori* (Não-Informativas):

- $\pi(\mu|\tau, \mu_0, \tau_0) \sim N\left(\mu_0, \frac{1}{\tau\tau_0}\right) = N\left(0, \frac{1}{\tau 10^{-4}}\right);$
- $\pi(\tau|\alpha, \beta) \sim \text{Gamma}\left(\frac{\alpha}{2}, \frac{\beta}{2}\right) = \text{Gamma}\left(\frac{2}{2}, \frac{0,002}{2}\right).$


## Quantidades de Interesse:

- $\mu;$
- $\sigma = \sqrt{\frac{1}{\tau}};$
- Tempo Mediano de Falha:  $t_{0.5} = \exp(\mu);$
- Tempo Médio de Falha:  $E(T) = \exp\left(\mu + \frac{1}{2\tau}\right).$


# Exemplo: Dados de Câncer de Bexiga

## Convergência das Cadeias e Densidade Marginal *a posteriori*


Convergência de  $\mu$




Convergência de Med(T)



Densidade de  $\mu$



Densidade de Med(T)



# Exemplo: Dados de Câncer de Bexiga

## Estimativas Pontuais:

	$\mu$	$\sigma$	$E(T)$	$t_{0,5}$
Inferência Clássica	2,72	0,76	20,3	15,2
Inferência Bayesiana	2,72	0,75	20,8	15,4

## Estimativas Intervalares 95%:

	$E(T)$		$t_{0,5}$	
	LI	LS	LI	LS
Inferência Clássica	11,9	28,9	10,0	20,4
Inferência Bayesiana	13,5	31,0	10,5	21,1



# Referências

- COLOSIMO, E. e GIOLO, S., Análise de Sobrevivência Aplicada, ABE-Projeto Fisher, 2006.
- HAMADA, M. et.al., Bayesian Reliability, Springer, 2008.
- IBRAHIM, J. et.al., Bayesian Survival Analysis, Springer, 2001.