

# Introdução à Inferência Bayesiana

Prof. Caio Azevedo

- Considere que desejamos estimar a renda média (em salários mínimos) do Brasil em 2012. Para isso, será retirada uma amostra segundo algum plano amostral.
- Podemos super algum modelo estatístico (distribuição de probabilidade) ou simplesmente considerar a média amostral como estimador (naturalmente o plano amostral deve ser levado em consideração).
- Suponha que o tamanho da população ( $N$ ) é substancialmente maior do que o tamanho da amostra ( $n$ ) e que o plano amostral foi AASs (sem reposição). Nesse caso, de um modo geral, podemos considerar que o plano foi AASc (com reposição).





- Assumimos que as observações (amostra) são i.i.d  
 $X \sim \text{exp}(\mu), \mathcal{E}(X) = \mu, p_X(x|\mu) = \frac{1}{\mu} e^{-x/\mu} \mathbf{1}_{(0,\infty)}(x).$
- Parâmetro de interesse  $\mathcal{E}(X) = \mu$
- Estimador de máxima verossimilhança de  $\mu$  é  $\hat{\mu} = \bar{X}$  e  $\mathcal{V}(\bar{X}) = \frac{\mu^2}{n}.$
- Resultado assintótico:  $IC(\mu, \gamma) = \bar{X} \pm z_\gamma \frac{\bar{X}}{\sqrt{n}}, \frac{1-\gamma}{2} = P(Z > z_\gamma).$ 
  - Tamanho da amostra tem de ser suficientemente grande.
  - O IC permite valores negativos.
  - Como incorporar informações adicionais (além do plano amostral)?

- Suponha que em uma pesquisa anterior chegou-se à  $E(X) = \tilde{\mu} = 4,00$ . Os especialistas afirmam que, muito provavelmente, a renda média do Brasil aumentou desde então e que sua distribuição deslocou-se para à direita (quartis aumentaram).
- Como incorporar essa informação acima e não utilizar resultados assintóticos?
- Vamos introduzir a informação acima em termos do cálculo de probabilidades, afirmando “à priori” que:

$$p_{\mu}(\mu|\alpha, \beta) = p_{\mu}(\mu) = \frac{\beta^{\alpha}}{\Gamma(\alpha)} \mu^{(-\alpha-1)} e^{-\beta/\mu} \mathbf{1}(\mu)_{(0, \infty)}$$

em que  $\mathcal{E}(\mu) = \frac{\beta}{\alpha - 1}, \alpha > 1$  e  $\mathcal{V}(\mu) = \frac{\beta^2}{(\alpha - 1)^2(\alpha - 2)}, \alpha > 2$ .

# Diferentes prioris, $\alpha = 21$



# Ingredientes

- Conhecimento (Informação) à priori

$$p(\mu) = \frac{\beta^\alpha}{\Gamma(\alpha)} \mu^{-(\alpha+1)} e^{-\beta/\mu} \mathbf{1}(\mu)_{(0,\infty)}.$$

- Informação obtida através do processo de amostragem (verossimilhança),  $\mathbf{x} = (x_1, \dots, x_n)$ .

$$L(\mu) = p(\mathbf{x}|\mu) = \prod_{i=1}^n \left\{ \mu^{-1} e^{-x_i/\mu} \right\} = \mu^{-n} e^{-n\bar{x}/\mu}$$

- Conhecimento à posteriori (depois de observar os dados)

$$p(\mu|\mathbf{x}) = \frac{p(\mu, \mathbf{x})}{p(\mathbf{x})} = \frac{p(\mu)p(\mathbf{x}|\mu)}{\int_{\mathcal{R}^+} p(\mu)p(\mathbf{x}|\mu)d\mu}$$

# Ingredientes

- Pode-se provar que (exercício):


$$p(\mu|\mathbf{x}) = \frac{(n\bar{x} + \beta)^{n+\alpha}}{\Gamma(n + \alpha)} \mu^{-(n+\alpha+1)} e^{-\frac{n\bar{x}+\beta}{\mu}} \mathbb{1}_{(0,\infty)}(\mu)$$

- A distribuição à priori normal inversa é conjugada para o modelo exponencial (com a parametrização adotada).
- Nesse caso, temos que:  $\mathcal{E}(\mu|\mathbf{X}) = \frac{n\bar{x} + \beta}{n + \alpha - 1}$  e


$$\mathcal{V}(\mu|\mathbf{X}) = \frac{(n\bar{x} + \beta)^2}{(n + \alpha - 1)^2(n + \alpha - 2)}.$$

# Priori, verossimilhança e posteriori $\alpha = 21$


funcoes escalonadas, beta = 40




funcoes escalonadas, beta = 60



funcoes escalonadas, beta = 80



funcoes escalonadas, beta = 100









# Comparação “frequentista” entre os estimadores MV e EAP

■ Temos que:  $\mathcal{E}(\hat{\mu}) = \mu$  e  $EQM(\hat{\mu}) = \mathcal{V}(\hat{\mu}) = \frac{\mu^2}{n}$ .

■ Pode-se provar que:  $\mathcal{E}_{X|\mu}(\mu|\mathbf{X}) = \frac{n\mu + \beta}{n + \alpha - 1}$ ,

$$\mathcal{V}_{X|\mu}(\mu) = \frac{\mu^2}{n(n + \alpha - 1)^2} \text{ e}$$

$$EQM_{X|\mu}(\mu|\mathbf{X}) = \frac{n\mu^2 - [\beta - \mu(\alpha - 1)]^2}{(n + \alpha - 1)^2}.$$

EQM  $\alpha = 21$ 

# Comparação

- Para uma amostra de tamanho  $n = 50$  simulada de  $X \sim \exp(5, 5)$ .

<b>Estimador</b>	<b>Estimativa</b>	<b>Variância Estimada</b>
MV	6,28	0,89
EAP com $\beta = 40$	5,06	0,63
EAP com $\beta = 60$	5,34	0,63
EAP com $\beta = 80$	5,63	0,63
EAP com $\beta = 100$	5,91	0,63

# Introdução

- Inferência Bayesiana: aprendizado, combinação entre o conhecimento previo e resultados de alguma pesquisa (no sentido amplo da palavra).
- Parâmetro: tratado como variável aleatória (pode ou não ser considerado “fixo”).
- Incerteza: introduzida através da priori e atualizada combinando-a com a verossimilhança.

# Definições e Notações

- Consideramos um modelo estatístico formado por  $(\Omega, \mathcal{A}, \mathcal{P})$ , (espaço amostral, sigma álgebra de eventos de  $\Omega$ , família de medidas de probabilidade).
- $\mathcal{P} = \{\mathcal{P}_\theta : \theta \in \Theta\}$ ,  $\Theta \subset \mathcal{R}^p$  (em geral infinito não-enumerável).  
Basicamente:  $\mathcal{P}_\theta = F_{X|\theta}(\cdot)$  (postulado).
- Realizar inferência Bayesiana (estimação pontual, intervalar e testar hipóteses estatísticas) em um dado espaço estatístico.
- $p^* = \{p_\theta : \theta \in \Theta\}$  (distribuição à priori). Os elementos de  $p^*$  não precisam ser fdp (função de probabilidade ou função densidade de probabilidade).

# Continuação

- Suporte da fdp:
  - $\Omega = \{x : f_{X|\theta} \geq 0\}$ ,  $f_{X|\theta}(\cdot)$  é a fdp associada à fda  $F_{X|\theta}(\cdot)$ .  
Eventualmente os subíndices podem ser suprimidos.
- Assim,  $(\Omega, \Theta)$  passa a ser nosso conjunto de interesse.
- Amostra aleatória (aa):  $X_1|\theta, \dots, X_n|\theta$  são condicionalmente independentes (dado  $\theta$ ) e identicamente distribuídas segundo  $X|\theta \sim F_{X|\theta}$ . Eventualmente, as suposições de independência e mesma distribuição podem ser relaxadas.
- Variável aleatória:  $X_i|\theta$ . Valor observado:  $x_i$ .

# Continuação

- Se  $X_1|\theta, \dots, X_n|\theta$  é uma aa de  $X|\theta$ ,  $X_1, \dots, X_n$  serão permutáveis (mais adiante).  $\underline{X} = \mathbf{X} = (X_1, \dots, X_n)$ .
- Estimador  $\hat{\theta}_{EAP} = \mathcal{E}(\theta|\mathbf{X})$ .
- Estimativa  $\tilde{\theta}_{EAP} = \mathcal{E}(\theta|\mathbf{x})$ .
- Estimador  $\hat{\theta}_{Mo} = \text{Moda}(\theta|\mathbf{X})$ .
- Estimativa  $\tilde{\theta}_{Mo} = \text{Moda}(\theta|\mathbf{x})$ .
- Estimador  $\hat{\theta}_{Md} = \text{Med}(\theta|\mathbf{X})$ .
- Estimativa  $\tilde{\theta}_{Md} = \text{Med}(\theta|\mathbf{x})$ .
- Medida de precisão do estimador (basicamente frequentista),  
 $\mathcal{V}_{X|\theta}(\hat{\theta})$ .

# Revisão de Cálculo de probabilidades

- Usaremos, em geral,  $p(\cdot)$  para denotarmos fdp's.
- Sejam  $X$ ,  $Y$  e  $Z$  va's em um mesmo espaço de probabilidade.

$$p(x|y) = \begin{cases} \frac{p(x, y)}{p(y)}, & \text{se } p(y) > 0, \\ 0, & \text{se } p(y) = 0 \end{cases}$$

$$p(x) = \begin{cases} \sum_y p(x, y), & \text{se } y \text{ for discreto,} \\ \int_{\Omega_y} p(x, y) dy, & \text{se } y \text{ for contínuo} \end{cases}$$



# Revisão de Cálculo de probabilidades

- $E_X(X) = E_Y(E_{X|Y}(X|Y))$  e  
 $V_X(X) = E_Y[V_{X|Y}(X|Y)] + V_Y[E_{X|Y}(X|Y)]$ .
- $p(x, y) = p(x|y)p(y) = p(y|x)p(x)$
- X e Y são independentes se e somente se  $p(x, y) = p(x)p(y)$   
( $\rightarrow p(x|y) = p(x)$  e  $p(y|x) = p(y)$ ).
- X e Y são condicionalmente independentes dado Z se e somente se  
 $p(x, y|z) = p(x|z)p(y|z)$   
( $\rightarrow p(x|y, z) = p(x|z)$  e  $p(y|x, z) = p(y|z)$ ).

# Breve histórico

- Teorema de Bayes  $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$ , publicado em 1763, *An Essay towards solving a Problem in the Doctrine of Chances*.
- Fundamentos Bayesianos: Bruno de Finetti, Jim Berger entre outros.
- Existem algumas correntes de pensamento dentro da inferência Bayesiana:
  - Priori tem de ser completamente especificada usando conhecimento prévio.
  - Priori pode ser total ou parcialmente obtida através dos dados.

## IF x IB

<b>Aspecto</b>	<b>Inferência Frequentista</b>	<b>Inferência Bayesiana</b>
Conhecimento:	verossimilhança	verossimilhança e priori
Parâmetros:	quantidades fixas	quantidades fixas mas de caráter aleatório ou totalmente aleatório
Teoria Assintótica	Fundamental	Pouco usada
Métodos computacionais	Extremamente dependente	Imprescindível na grande maioria das situações
Probabilidade:	limite de frequências relativas	medida de credibilidade

## IF x IB

<b>Aspecto</b>	<b>Inferência Frequentista</b>	<b>Inferência Bayesiana</b>
Estimação pontual:	máxima verossimilhança, mínimos quadrados	quantis da posteriori e risco de Bayes
Estimação intervalar:	limites são aleatórios	parâmetro é aleatório
Teste de hipótese:	estatística, região crítica, poder, TUMP	Probabilidade das hipóteses serem verdadeiras