

# Aula de Exercícios 2: Inferência Bayesiana - Prioris, Posteriores e Estimação Pontual e Intervalar

Prof. Caio Azevedo

## Modelo $N(\mu, \sigma^2)$

- Seja  $X_i | \boldsymbol{\theta} \stackrel{iid}{\sim} N(\mu, \sigma^2)$ ,  $\boldsymbol{\theta} = (\mu, \sigma^2)'$ . Temos que:

$$L(\boldsymbol{\theta}) \propto (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$$

- Para  $\sigma^2$  conhecido, temos que:

$$L(\mu) \propto \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n [(x_i - \bar{x}) + (\bar{x} - \mu)]^2 \right\}$$

## Modelo $N(\mu, \sigma^2)$ , $\sigma^2$ conhecido

- Cont.

$$L(\mu) \propto \exp \left\{ -\frac{n}{2\sigma^2} (\mu - \bar{x})^2 \right\},$$

que se assemelha ao núcleo de uma distribuição  $N(\bar{x}, \sigma^2/n)$ . Logo a família conjugada de prioris para a distribuição  $N(\mu, \sigma^2)$  com  $\sigma^2$  conhecido, é a distribuição  $N(a, b)$ .

- Posteriori

$$p(\mu|\mathbf{x}) \propto \exp \left\{ -\frac{n}{2\sigma^2} (\mu - \bar{x})^2 \right\} \exp \left\{ -\frac{1}{2b} (\mu - a)^2 \right\}$$

# Modelo $N(\mu, \sigma^2)$ , $\sigma^2$ conhecido

## ■ Posteriores (cont.)

$$\begin{aligned} p(\mu|\mathbf{x}) &\propto \exp \left\{ -\frac{1}{2} \left[ \frac{n\mu^2}{\sigma^2} + \frac{\mu^2}{b} - 2\frac{\mu\bar{x}}{\sigma^2} - 2\frac{\mu a}{b} \right] \right\} \\ &\propto \exp \left\{ -\frac{1}{2} \left[ \mu^2 \frac{nb + \sigma^2}{\sigma^2 b} - 2\mu \frac{\bar{x}b + \sigma^2 a}{\sigma^2 b} \right] \right\} \\ &\propto \exp \left\{ -\frac{1}{2} \frac{nb + \sigma^2}{\sigma^2 b} \left[ \mu^2 - 2\mu \frac{\bar{x}b + \sigma^2 a}{nb + \sigma^2} \right] \right\} \\ &= \exp \left\{ -\frac{1}{2\psi} [\mu^2 - 2\mu\lambda] \right\} \propto \psi^{-1/2} \exp \left\{ -\frac{1}{2\psi} (\mu - \lambda)^2 \right\} \end{aligned}$$

que corresponde ao núcleo de uma distribuição  $N(\lambda, \psi)$ , em que

$$\lambda = \frac{\bar{x}b + \sigma^2 a}{nb + \sigma^2} \text{ e } \psi = \frac{\sigma^2 b}{nb + \sigma^2}. \text{ Assim, } \mu|\mathbf{x} \sim N(\lambda, \psi)$$

## Modelo $N(\mu, \sigma^2)$ , $\sigma^2$ conhecido

- Com os resultados do slide anterior fica simples obter estimativas pontuais e intervalares.
- Preditiva: Temos que  $X_{n+1}|\mu \sim N(\mu, \sigma^2)$  e  $\mu|\mathbf{x} \sim N(\lambda, \psi)$ .
- Logo, pelas propriedades descritas no slide 3 desse [link](#), temos que  $X_{n+1}|\mathbf{x} \sim N(\lambda, \sigma^2 + \psi)$ .

## Modelo $N(\mu, \sigma^2)$ , com $\mu$ conhecido

- Temos que:

$$L(\boldsymbol{\theta}) \propto (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$$

que se assemelha ao núcleo de uma distribuição

$IG(n/2 - 1, \sum_{i=1}^n (x_i - \mu)^2 / 2)$ . Assim, a família de prioris conjugada para o modelo  $N(\mu, \sigma^2)$  com  $\mu$  conhecido é a distribuição  $IG(a, b)$ .

- Posteriori:

$$\begin{aligned} p(\sigma^2 | \mathbf{x}) &\propto (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\} \\ &\propto (\sigma^2)^{-a-1} \exp \left\{ -\frac{b}{\sigma^2} \right\} \end{aligned}$$

## Modelo $N(\mu, \sigma^2)$ , com $\mu$ conhecido

- (cont.) Posteriori:

$$p(\sigma^2 | \mathbf{x}) \propto (\sigma^2)^{-n/2-a-1} \exp \left\{ -\frac{1}{\sigma^2} \left[ \frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2 + b \right] \right\}$$

que se assemelha ao núcleo de uma distribuição  $IG(a^*, b^*)$ , em que

$$a^* = \frac{n}{2} + a \text{ e } b^* = \frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2 + b. \text{ Logo } \sigma^2 | \mathbf{x} \sim IG(a^*, b^*)$$

- Consequentemente, dado resultados anteriores, a obtenção de estimativas pontuais e intervalares fica fácil.
- Vamos provar agora que:  $X_{n+1} | \mathbf{x} \sim t_{(2a^*)} \left( \mu, \sqrt{\frac{b^*}{a^*}} \right)$

## Modelo $N(\mu, \sigma^2)$ , com $\mu$ conhecido

### ■ Preditiva:

$$\begin{aligned} p(x_{n+1} \equiv x | \mathbf{x}) &= \int_0^\infty \frac{1}{\sqrt{2\pi}(\sigma^2)^{1/2}} \exp \left\{ -\frac{1}{2\sigma^2} (x - \mu)^2 \right\} \\ &\times \frac{(b^*)^{a^*}}{\Gamma(a^*)} (\sigma^2)^{-a^*-1} \exp \left\{ -\frac{b^*}{\sigma^2} \right\} \mathbb{1}_{\mathcal{R}}(x) d\sigma^2 \\ &= \frac{1}{\sqrt{2\pi}} \frac{(b^*)^{a^*}}{\Gamma(a^*)} \int_0^\infty (\sigma^2)^{a^*-1/2-1} \\ &\times \exp \left\{ -\frac{1}{\sigma^2} \left[ \frac{(x - \mu)^2}{2} + b^* \right] \right\} \mathbb{1}_{\mathcal{R}}(x) d\sigma^2 \\ &= \frac{1}{\sqrt{2\pi}} \frac{(b^*)^{a^*}}{\Gamma(a^*)} \frac{\Gamma(a^* + 1/2)}{\left[ \frac{(x - \mu)^2}{2} + b^* \right]^{a^*+1/2}} \mathbb{1}_{\mathcal{R}}(x) \end{aligned}$$



## Modelo $N(\mu, \sigma^2)$ , com $\mu$ conhecido

- Preditiva (cont.), ( $\nu = 2a^*$ ):

$$\begin{aligned} p(x_{n+1} \equiv x | \mathbf{x}) &= \frac{1}{\sqrt{2\pi}} \frac{(b^*)^{a^*}}{\Gamma(a^*)} \frac{\Gamma(a^* + 1/2)}{\left[ \frac{(x - \mu)^2}{2} + b^* \right]^{a^* + 1/2}} \mathbb{1}_{\mathcal{R}}(x) \\ &= \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right) \sqrt{2\pi a^*} \sqrt{b^*/a^*}} \frac{\mathbb{1}_{\mathcal{R}}(x)}{\left[ \left( \frac{x - \mu}{\sqrt{b^*/a^*}} \right)^2 \frac{1}{2a^*} + 1 \right]^{\frac{2a^*+1}{2}}} \\ &= \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right) \sqrt{\pi\nu} \sqrt{b^*/a^*}} \frac{\mathbb{1}_{\mathcal{R}}(x)}{\left[ \left( \frac{x - \mu}{\sqrt{b^*/a^*}} \right)^2 \frac{1}{\nu} + 1 \right]^{\frac{\nu+1}{2}}} \end{aligned}$$

## Exemplo (exponencial deslocada)

- Seja  $X|\theta \sim \text{exp}D_{(\mu, \infty)}(\theta)$ , em que  $\theta = (\mu, \sigma)'$  (exponencial deslocada à direita do zero, de parâmetros  $\theta$ , em que  $\mu \in \mathcal{R}$  e  $\sigma \in \mathcal{R}^+$ ), então:

$$p(x|\theta) = \frac{1}{\sigma} \exp \left\{ -\frac{(x - \mu)}{\sigma} \right\} \mathbb{1}_{(\mu, \infty)}(x)$$

- Exercício: Se  $Y = X - \mu$ , então  $Y|\sigma \sim \text{exp}(\sigma)$ . Logo:

$$\mathcal{E}(X|\theta) = \mathcal{E}(Y|\sigma) + \mu = \sigma + \mu$$

$$\mathcal{V}(X|\theta) = \mathcal{V}(Y|\sigma) = \sigma^2$$

## Exemplo (exponencial deslocada)

- Verossimilhança

$$L(\theta) = \sigma^{-n} \exp \left\{ -\frac{n(\bar{x} - \mu)}{\sigma} \right\} \prod_{i=1}^n \mathbb{1}_{(\mu, \infty)}(x_i),$$

mas, definindo  $y_1 = \min \{x_1, \dots, x_n\}$  e  $y_n = \max \{x_1, \dots, x_n\}$ , temos que:

$$\begin{aligned} \prod_{i=1}^n \mathbb{1}_{(\mu, \infty)}(x_i) = 1 &\Leftrightarrow \mathbb{1}_{(\mu, \infty)}(y_1) \mathbb{1}_{(y_1, \infty)}(y_n) = 1 \\ &\Leftrightarrow \mathbb{1}_{(\mu, y_n)}(y_1) \mathbb{1}_{(\mu, \infty)}(y_n) = 1 \end{aligned}$$

- Logo,

$$L(\theta) \propto \sigma^{-n} \exp \left\{ -\frac{n(\bar{x} - \mu)}{\sigma} \right\} \mathbb{1}_{(\mu, \infty)}(y_1)$$

## $\mu$ conhecido

- Verossimilhança

$$L(\sigma) \propto \sigma^{-n} \exp \left\{ -\frac{n(\bar{x} - \mu)}{\sigma} \right\}$$

que se assemelha ao núcleo de uma distribuição  $IG(n + 1, n(\bar{x} - \mu))$ .

Assim, a  $IG(a, b)$  é a família conjugada de prioris para o modelo  $\exp D_{(\mu, \infty)}(\theta)$  com  $\mu$  conhecido.

- Priori não informativa  $p(\sigma) \propto \mathbf{1}_{\mathcal{R}^+}(\sigma)$ .

- Priori de Jeffreys:

$$l(\sigma) = -n \ln \sigma - \frac{n(\bar{x} - \mu)}{\sigma} + c$$

## $\mu$ conhecido

- (Cont.) Além disso:

$$S(\sigma) = -\frac{n}{\sigma} + \frac{n(\bar{x} - \mu)}{\sigma^2}$$

$$H(\sigma) = \frac{n}{\sigma^2} - 2\frac{n(\bar{x} - \mu)}{\sigma^3}$$

$$I(\sigma) = -\frac{n}{\sigma^2} + 2\frac{n\sigma}{\sigma^3} = \frac{n}{\sigma^2}$$

- Logo,  $p^J(\sigma) \propto \sigma^{-1} \mathbb{1}_{\mathcal{R}^+}(\sigma)$

## $\mu$ conhecido

- Priori conjugada (repetir os os desenvolvimentos a seguir para as outras duas prioris e comparar os resultados).

$$\begin{aligned} p(\sigma|\mathbf{x}) &\propto \sigma^{-n} \exp\left\{-\frac{n(\bar{x} - \mu)}{\sigma}\right\} \sigma^{-a-1} \exp\left\{-\frac{b}{\sigma}\right\} I_{\mathcal{R}^+}(\sigma) \\ &= \sigma^{-n-a-1} \exp\left\{-\frac{n(\bar{x} - \mu) + b}{\sigma}\right\} I_{\mathcal{R}^+}(\sigma) \end{aligned}$$

que corresponde ao núcleo de uma distribuição  $IG(a^*, b^*)$ , em que  $a^* = n + a$ ,  $b^* = n(\bar{x} - \mu) + b$ .

## $\mu$ conhecido

- O estimador de Bayes sobre perda quadrática é dado por  $\hat{\sigma}_{EAP}$ , ou seja

$$\hat{\sigma}_{EAP} = \frac{n(\bar{x} - \mu) + b}{n + a - 1}$$

- Além disso

$$\begin{aligned}\mathcal{E}_{\mathbf{X}|\sigma}(\hat{\sigma}_{EAP}) &= \frac{n\sigma + b}{n + a - 1} \\ \mathcal{V}_{\mathbf{X}|\sigma}(\hat{\sigma}_{EAP}) &= \frac{n\sigma^2}{(n + a - 1)^2} \\ \mathcal{B}_{\mathbf{X}|\sigma}(\hat{\sigma}_{EAP}) &= \frac{b - \sigma(a - 1)}{n + a - 1}\end{aligned}$$

## $\mu$ conhecido

- Cont.

$$\begin{aligned}\mathcal{E}QM_{\mathbf{X}|\sigma}(\hat{\sigma}_{EAP}) &= \frac{n\sigma^2}{(n+a-1)^2} + \frac{(b-\sigma(a-1))^2}{(n+a-1)^2} \\ &= \frac{n\sigma^2 + b^2 - 2(a-1)b\sigma + \sigma^2(a-1)^2}{(n+a-1)^2} \\ &= \frac{\sigma^2(n+(a-1)^2) - 2(a-1)b\sigma + b^2}{(n+a-1)^2}\end{aligned}$$

- O estimador **minimax** para a perda quadrática é obtido quando o risco frequentista não depende de  $\sigma$ . Neste caso seria o  $\mathcal{E}QM_{\mathbf{X}|\sigma}(\hat{\sigma}_{EAP})$  não depender de  $\sigma$ .



## $\mu$ conhecido

- Cont. Contudo, neste caso, não há estimador minimax pois, teríamos de escolher  $(a - 1)^2 = -n$  e  $b = 0$ , que não são valores permitidos para os hiperparâmetros.
- Vamos comparar os estimadores de MV com o EAP para um caso limite:  $a = b \rightarrow 0$ .
- (Exercício): Temos que  $\hat{\sigma}_{MV} = \bar{X} - \mu$ . Assim,  $\mathcal{E}_{\mathbf{X}|\sigma}(\hat{\sigma}_{MV}) = \mu$ ,  $\mathcal{B}_{\mathbf{X}|\sigma}(\hat{\sigma}_{MV}) = 0$ ,  $\mathcal{V}_{\mathbf{X}|\sigma}(\hat{\sigma}_{MV}) = \mathcal{EQM}_{\mathbf{X}|\sigma}(\hat{\sigma}_{MV}) = \frac{\sigma^2}{n}$ .
- Note que, para  $a = b \rightarrow 0$ , temos que  $\mathcal{EQM}_{\mathbf{X}|\sigma}(\hat{\sigma}_{EAP}) = \frac{\sigma^2(n+1)}{(n-1)^2}$

## $\mu$ conhecido

- Cont. Assim:

$$\frac{\mathcal{E}QM_{\mathbf{x}|\sigma}(\hat{\sigma}_{MV})}{\mathcal{E}QM_{\mathbf{x}|\sigma}(\hat{\sigma}_{EAP})} = \frac{(n-1)^2}{n(n+1)} < 1 \Leftrightarrow n^2 - 2n + 1 < n^2 + n$$
$$\Leftrightarrow -3n + 1 < 0 \Leftrightarrow n > \frac{1}{3}$$

- Assim, essencialmente, o estimador  $\hat{\sigma}_{MV}$  é uniformemente melhor (em relação à  $(n, \sigma^2, \mu)$ ), em comparação à  $\hat{\sigma}_{EAP}$ .
- $IC_B(\sigma; \gamma) \equiv IC(\sigma; \gamma)$ . Uma vez que  $\sigma|\mathbf{x} \sim IG(a^*, b^*)$ , então  $\sigma^{-1}|\mathbf{x} \sim \text{gama}(a^*, (b^*)^{-1})$ .
- Logo, se  $\theta = 2b^*\sigma^{-1}$ , então  $\theta|\mathbf{x} \sim \chi^2_{(2a^*)}$

## $\mu$ conhecido

- Portanto:

$$P(q_1 < 2b^* \sigma^{-1} < q_2 | \mathbf{x}) = \gamma$$

$$P\left(\frac{2b^*}{q_2} < \sigma < \frac{2b^*}{q_1} | \mathbf{x}\right) = \gamma$$

- Assim:  $IC_B(\sigma, \gamma) = \left[\frac{2b^*}{q_2}; \frac{2b^*}{q_1}\right]$ , em que  $P(X < q_1) = \frac{1-\gamma}{2}$ ,  
 $P(X < q_2) = \frac{1+\gamma}{2}$ ,  $X \sim \chi^2_{(2a^*)}$ .

## $\sigma$ conhecido

- Temos que:

$$L(\mu) \propto \exp\left\{\frac{n\mu}{\sigma}\right\} \mathbb{1}_{(-\infty, y_1)}(\mu)$$

que não corresponde ao núcleo de nenhuma distribuição conhecida (“to the best of my knowledge”).

- Não é possível obter a informação de Fisher (priori de Jeffreys).
- Exercício: tente encontrar a família conjugada de prioris.

## $\sigma$ conhecido

- Vamos assumir:  $p(\mu) \propto \mathbb{1}_{\mathcal{R}}(\mu)$ , assim

$$\begin{aligned} p(\mu|\mathbf{x}) &\propto \exp\left\{\frac{n\mu}{\sigma}\right\} \mathbb{1}_{(-\infty, y_1)}(\mu) \mathbb{1}_{\mathcal{R}}(\mu) \\ &\propto \exp\left\{\frac{n\mu}{\sigma}\right\} \mathbb{1}_{(-\infty, y_1)}(\mu) \end{aligned}$$

- Obs: Logo que cheguei ao resultado acima, não me atentei que ele se assemelha ao núcleo de uma distribuição  $\exp D_{(-\infty, y_1)}(y_1, \sigma/n)$ . Dessa forma, procedi ao processo de obtenção da posteriori de forma usual.

## $\sigma$ conhecido

- Por outro lado, temos que:

$$p(\mathbf{x}) = \int_{-\infty}^{y_1} \exp\left\{\frac{n\mu}{\sigma}\right\} d\mu = \frac{\sigma}{n} \exp\left\{\frac{ny_1}{\sigma}\right\}$$

- Portanto

$$p(\mu|\mathbf{x}) = \frac{p(\mathbf{x}|\mu)p(\mu)}{p(\mathbf{x})} = \frac{\sigma}{n} \exp\left\{\frac{n(\mu - y_1)}{\sigma}\right\} \mathbb{1}_{(-\infty, y_1)}(\mu)$$

- Por outro lado, se  $\mu^* = -(\mu - y_1)$ , então  $\mu^*|\mathbf{x} \sim \exp(\sigma/n)$ . Assim

$$\begin{aligned}\hat{\mu}_{EAP} = \mathcal{E}(\mu|\mathbf{x}) &= y_1 - \frac{\sigma}{n} \\ \mathcal{V}(\mu|\mathbf{x}) &= \frac{\sigma^2}{n^2}\end{aligned}$$

## $\sigma$ conhecido

- Além disso, é possível provar que  $\hat{\mu}_{MV} = Y_1$  é o estimador de MV de  $\mu$ .
- (exercício) Por outro lado, temos que  $S_{Y_1}(y_1|\mu) = (S_X(y_1|\mu))^n$ , em que  $S_X(x|\mu) = e^{-\frac{x-\mu}{\sigma}}$  é a fds (função de sobrevivência) de  $X|\mu \sim \text{expD}_{(\mu, \infty)}(\mu)$ .
- Logo  $S_{Y_1}(y_1|\mu) = e^{-\frac{y_1-\mu}{\sigma/n}} \rightarrow f_{Y_1}(y_1|\mu) = \frac{n}{\sigma} \exp\left\{-\frac{y_1-\mu}{\sigma/n}\right\} \mathbb{1}_{(\mu, \infty)}(y_1)$ .  
Portanto,  $Y_1|\mu \sim \text{expD}_{(\mu, \infty)}(\mu)$ , com  $\sigma^2$  conhecido. Dessa forma:

$$\begin{aligned}\mathcal{E}_{X|\mu}(Y_1) &= \frac{\sigma}{n} + \mu \\ \mathcal{V}_{X|\mu}(Y_1) &= \frac{\sigma^2}{n^2}\end{aligned}$$

## $\sigma$ conhecido

■ Assim:

■  $\hat{\mu}_{MV} = Y_1$

$$\begin{aligned}\mathcal{E}_{\mathbf{X}|\mu}(\hat{\mu}_{MV}) &= \frac{\sigma}{n} + \mu; \mathcal{B}_{\mathbf{X}|\mu}(\hat{\mu}_{MV}) = \frac{\sigma}{n} \\ \mathcal{V}_{\mathbf{X}|\mu}(\hat{\mu}_{MV}) &= \frac{\sigma^2}{n^2}; \mathcal{EQM}_{\mathbf{X}|\mu}(\hat{\mu}_{MV}) = \frac{2\sigma^2}{n^2}\end{aligned}$$

■  $\hat{\mu}_{EAP} = Y_1 - \frac{\sigma}{n}$

$$\begin{aligned}\mathcal{E}_{\mathbf{X}|\mu}(\hat{\mu}_{EAP}) &= \mu; \mathcal{B}_{\mathbf{X}|\mu}(\hat{\mu}_{EAP}) = 0 \\ \mathcal{V}_{\mathbf{X}|\mu}(\hat{\mu}_{EAP}) &= \frac{\sigma^2}{n^2}; \mathcal{EQM}_{\mathbf{X}|\mu}(\hat{\mu}_{EAP}) = \frac{\sigma^2}{n^2}\end{aligned}$$



## $\sigma$ conhecido

- Como o emv é viciado é o estimador EAP não o é, vamos comparar os EQM's dos dois estimadores, ou seja:

$$\frac{\mathcal{E}QM_{\mathbf{X}|\mu}(\hat{\mu}_{MV})}{\mathcal{E}QM_{\mathbf{X}|\mu}(\hat{\mu}_{EAP})} = 2 > 1$$

- Assim, o estimador EAP é uniformemente melhor (em termos de  $n, \mu\sigma$ ) do que o estimador de mv.
- Além disso, como o risco frequentista da EAP (que neste caso é o EQM, que coincide com a Var) não depende de  $\mu$ , ele também é um estimador minimax. Também, ele é o **ENVVUM**.

## $\sigma$ conhecido

- Para obter um  $IC_B(\mu; \gamma)$ , lembremos que  $\mu^* | \mathbf{x} \sim \exp(\sigma/n)$ . Assim:

$$P(q_1 \leq \mu^* \leq q_2 | \mathbf{x}) = \gamma \leftrightarrow P(y_1 - q_2 \leq \mu \leq y_1 - q_1 | \mathbf{x}) = \gamma$$

- em que  $F_X(q_1) = 1 - \exp\left\{-\frac{q_1}{\sigma/n}\right\} = \frac{1-\gamma}{2}$  e

$$S_X(q_2) = \exp\left\{-\frac{q_2}{\sigma/n}\right\} = \frac{1-\gamma}{2}, \text{ em que } X | \mu \sim \exp(\sigma/n). \text{ Ou}$$

$$\text{seja, } q_1 = -\frac{\sigma}{n} \ln\left(\frac{1+\gamma}{2}\right) \text{ e } q_2 = -\frac{\sigma}{n} \ln\left(\frac{1-\gamma}{2}\right).$$

- Logo  $IC_B(\mu; \gamma) = [y_1 - q_2; y_1 - q_1]$

## $\theta$ desconhecido

- Vamos assumir uma priori não informativa (imprópria), ou seja

$$p(\theta) \propto \mathbb{1}_{\mathcal{R}}(\mu)\mathbb{1}_{\mathcal{R}^+}(\sigma)$$

- Logo,

$$\begin{aligned} p(\theta) &\propto \sigma^{-n} \exp \left\{ -\frac{n(\bar{x} - \mu)}{\sigma} \right\} \mathbb{1}_{\mathcal{R}}(\mu)\mathbb{1}_{(-\infty, y_1)}(\mu)\mathbb{1}_{\mathcal{R}^+}(\sigma) \\ &= \sigma^{-n} \exp \left\{ -\frac{n(\bar{x} - \mu)}{\sigma} \right\} \mathbb{1}_{(-\infty, y_1)}(\mu)\mathbb{1}_{\mathcal{R}^+}(\sigma) \end{aligned}$$

- A qual não corresponde ao núcleo de nenhuma distribuição bivariada conhecida (“to the best of my knowledge”).

## $\theta$ desconhecido

- Por outro lado, temos que:

$$\begin{aligned} p(\mu|\mathbf{x}) &\propto \mathbb{1}_{(-\infty, y_1)}(\mu) \underbrace{\int_0^{\infty} \sigma^{-n} \exp\left\{-\frac{n(\bar{x} - \mu)}{\sigma}\right\} d\sigma}_{IG(n-1, n(\bar{x} - \mu))} \\ &= \frac{\Gamma(n-1)}{[n(\bar{x} - \mu)]^{n-1}} \mathbb{1}_{(-\infty, y_1)}(\mu) \end{aligned}$$

- A qual não corresponde ao núcleo de nenhuma distribuição univariada conhecida (“to the best of my knowledge”).
- Contudo, as contas necessárias (encontrar a constante de normalização e obter estimativas pontuais e intervalares) são simples, por se tratar de um polinômio (exercício).

## $\theta$ desconhecido

- Para  $\sigma$ , temos que:

$$\begin{aligned} p(\sigma|\mathbf{x}) &\propto \sigma^{-n} \exp\left\{-\frac{n\bar{x}}{\sigma}\right\} \mathbb{1}_{\mathcal{R}^+}(\sigma) \int_{-\infty}^{y_1} \exp\left\{\frac{n\mu}{\sigma}\right\} d\mu \\ &\propto \sigma^{-n-1} \exp\left\{-\frac{n(\bar{x} - y_1)}{\sigma}\right\} \mathbb{1}_{\mathcal{R}^+}(\sigma) \end{aligned}$$

que corresponde ao núcleo de uma distribuição  $IG(n, n(\bar{x} - y_1))$ .

- Logo, a obtenção de estimativas pontuais e intervalares seguem abordagens já apresentadas.
- Obs: Não é possível obter a priori de Jeffreys.