

Exercícios

Prof. Caio Azevedo

Normal inversa

- Seja $X_1, \dots, X_n \stackrel{iid}{\sim} X$, $X \sim NI(\mu, \lambda)$, $\theta = (\mu, \lambda)'$, $\mu, \lambda > 0$.
- Densidade

$$f_X(x; \theta) = \sqrt{\frac{\lambda}{2\pi x^3}} \exp\left\{-\frac{\lambda(x - \mu)^2}{2\mu^2 x}\right\} \mathbb{1}_{(0, \infty)}(x)$$

- Verossimilhança

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

- $\mathcal{E}(X) = \mu$, $\mathcal{V}(X) = \frac{\mu^3}{\lambda}$, $\mathcal{E}\left(\frac{1}{X}\right) = \frac{1}{\mu} + \frac{1}{\lambda}$, $\mathcal{V}\left(\frac{1}{X}\right) = \frac{1}{\mu\lambda} + \frac{2}{\lambda^2}$.

Normal inversa (λ conhecido)

■ Família exponencial

$$\begin{aligned}f_{\mathbf{X}}(\mathbf{x}; \mu) &= \left(\frac{\lambda}{2\pi}\right)^{n/2} \prod_{i=1}^n x_i^{-3} \exp\left\{-\frac{\lambda}{2\mu^2} \sum_{i=1}^n \frac{(x_i - \mu)^2}{x_i}\right\} \mathbb{1}_A(\mathbf{x}) \\&= \exp\left\{-\frac{\lambda}{2\mu^2} \sum_{i=1}^n x_i + \frac{n\lambda}{\mu} - \frac{\lambda}{2} \sum_{i=1}^n \frac{1}{x_i}\right\} \mathbb{1}_A(\mathbf{x}) \\&= \exp\left\{-\frac{\lambda}{2\mu^2} \sum_{i=1}^n x_i + \frac{n\lambda}{\mu}\right\} \exp\left\{-\frac{\lambda}{2} \sum_{i=1}^n \frac{1}{x_i}\right\} \mathbb{1}_A(\mathbf{x}) \\&= \exp\{c(\mu)t(\mathbf{x}) + d(\mu)\} h(\mathbf{x})\end{aligned}$$

em que $c(\mu) = -\frac{\lambda}{2\mu^2}$, $t(\mathbf{x}) = \sum_{i=1}^n x_i$, $d(\mu) = \frac{n\lambda}{\mu}$,

$h(\mathbf{x}) = \exp\left\{-\frac{\lambda}{2} \sum_{i=1}^n \frac{1}{x_i}\right\} \mathbb{1}_A(\mathbf{x})$, $\mathbb{1}_A(\mathbf{x}) = \prod_{i=1}^n I_{(0, \infty)}(x_i)$.

Normal inversa (λ conhecido)

- Logo $\mathbf{X} \sim FE_1(\mu)$ e $T = \sum_{i=1}^n X_i$ é uma estatística suficiente.
- Por outro lado, temos que:

$$f_{\mathbf{X}}(\mathbf{x}; \mu) = \exp \{ \eta t(\mathbf{x}) + d_0(\eta) \} h(\mathbf{x})$$

em que $\eta = -\frac{\lambda}{2\mu^2} \rightarrow \mu = \sqrt{-\frac{\lambda}{2\eta}}$ e $d_0(\eta) = n\sqrt{\frac{-2\eta}{\lambda}}$. Como

$\Theta_\eta = (-\infty, 0)$ contem algum segmento de reta, então T também é minimal e completa.

- Obs: $-d'_0(\eta) = n\sqrt{\lambda}(-2\eta)^{-1/2} \frac{2}{2} \rightarrow \mathcal{E}(T) = n\mu,$
 $-d''_0(\eta) = n\sqrt{\lambda}(-2\eta)^{-3/2} = n\lambda^{1/2} \left(\frac{\lambda}{\mu^2}\right)^{-3/2} \rightarrow \mathcal{V}(T) = \frac{n\mu^3}{\lambda}$

Normal inversa (λ conhecido)

- ENVUM, $\mathcal{E}(T) = n\mu \rightarrow \mathcal{E}\left(\frac{T}{n}\right) = \mu$. Logo $T^* = \frac{T}{n}$ é o ENVUM de μ , pelo TLS.
- EMM: Como $\mathcal{E}(X) = \mu$, então $\hat{\mu}_{MM} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ é o EMM de μ .
 - Temos que $\mathcal{E}(\hat{\mu}_{MM}) = \mu$ e $\mathcal{V}(\hat{\mu}_{MM}) = \frac{\mu^3}{\lambda n}$
- EMV: Temos que:

$$l(\mu) = -\frac{\lambda}{2} \sum_{i=1}^n \frac{(x_i - \mu)^2}{\mu^2 x_i} + \text{const.}$$

Normal inversa (λ conhecido)

- EMV: Temos que:

$$\begin{aligned} S(\mu) &= \frac{\partial l(\mu)}{\partial \mu} = -\frac{\lambda}{2} \sum_{i=1}^n \frac{-2(x_i - \mu)\mu^2 - 2(x_i - \mu)^2\mu}{\mu^4 x_i} \\ &= \frac{\lambda}{2} \sum_{i=1}^n \frac{2x_i\mu^2 - 2\mu^3 + 2x_i^2\mu - 4x_i\mu^2 + 2\mu^3}{\mu^4 x_i} \\ &= \lambda \sum_{i=1}^n \frac{x_i - \mu}{\mu^3} \\ H(\mu) &= \lambda \sum_{i=1}^n \frac{-\mu^3 - 3(x_i - \mu)\mu^2}{\mu^6} = \lambda \sum_{i=1}^n \frac{2\mu^3 - 3x_i\mu^2}{\mu^6} \end{aligned}$$

Normal inversa (λ conhecido)

- EMV: Temos que:

$$\begin{aligned}I(\mu) &= \frac{n\lambda}{\mu^3} \\S(\tilde{\mu}) &= 0 \rightarrow \tilde{\mu} = \bar{x} \\H(\tilde{\mu}) &= -\frac{n\lambda}{\bar{x}^3} < 0\end{aligned}$$

- Logo $\hat{\theta}_{MV} = \bar{X}$ é o emv de θ , (nesse caso $\hat{\theta}_{MV} = \hat{\theta}_{MM}$). Além disso, eles coincidem com o ENVUM.
- Note que $LICR(\theta) = \frac{\mu^3}{n\lambda} = \mathcal{V}(T^*) = \mathcal{V}(\bar{X})$.

Normal inversa (λ conhecido)

- Por outro lado, temos que:

$$S(\mu) = \frac{\lambda}{\mu^3} \left(\sum_{i=1}^n x_i - n\mu \right) = a(\mu) [t(\mathbf{x}) - \tau(\mu)]$$

- Assim, como $\mathbf{X} \in FE_1$, as condições de regularidade são válidas e, portanto temos que $T^* = \frac{1}{n} \sum_{i=1}^n X_i$ é o ENVUM de μ .

Normal inversa (λ conhecido)

- Intervalos de confiança.
- A fda de X não possui forma fechada, assim, usar o resultado $W = -2 \sum_{i=1}^n \ln F_X(X_i; \mu)$ não é útil.
- Contudo, $T^* = \frac{1}{n} \sum_{i=1}^n X_i \sim IG(\mu, n\lambda)$.
- Além disso, $Q = \frac{n\lambda(\bar{X} - \mu)^2}{\mu^2 \bar{X}} \sim \chi_1^2$.
- Portanto

$$P\left(q_1 < \frac{n\lambda(\bar{X} - \mu)^2}{\mu^2 \bar{X}} < q_2\right) = \gamma$$
$$\Leftrightarrow P\left(\sqrt{\frac{\bar{X}q_1}{n\lambda}} < \frac{(\bar{X} - \mu)}{\mu} < \sqrt{\frac{\bar{X}q_2}{n\lambda}}\right) = \gamma$$

Normal inversa (λ conhecido)

■ Cont.

$$P\left(\sqrt{\frac{\bar{X}q_1}{n\lambda}} + 1 < \frac{\bar{X}}{\mu} < \sqrt{\frac{\bar{X}q_2}{n\lambda}} + 1\right) = \gamma$$
$$\Leftrightarrow P\left(\bar{X}\left(\sqrt{\frac{\bar{X}q_2}{n\lambda}} + 1\right)^{-1} < \mu < \bar{X}\left(\sqrt{\frac{\bar{X}q_1}{n\lambda}} + 1\right)^{-1}\right) = \gamma$$

- Assim, $IC(\mu, \gamma) = \left[\bar{X}\left(\sqrt{\frac{\bar{X}q_2}{n\lambda}} + 1\right)^{-1}; \bar{X}\left(\sqrt{\frac{\bar{X}q_1}{n\lambda}} + 1\right)^{-1}\right]$, em que $P(X < q_1) = \frac{1-\gamma}{2}$, $P(X < q_2) = \frac{1+\gamma}{2}$, $X \sim \chi_1^2$.

Normal inversa (λ conhecido)

- TUMP: $H_0 : \mu \leq \mu_0$ vs $H_1 : \mu > \mu_0$
- Da forma da família exponencial, como $c(\mu)$ é crescente, então \mathbf{X} tem RVMND em $t = \sum_{i=1}^n x_i$. Logo, como $\lambda > 0$, então um TUMP é dado por:

$$\phi(t) = \begin{cases} 1, & \text{se } t > c \\ 0, & \text{cc} \end{cases} \quad (1)$$

em que $P_{\mu_0}(T > c) = \alpha$, em que se $\mu = \mu_0$, $T \sim NI(n\mu_0, n^2\lambda)$.

Normal inversa (λ conhecido)

- Como as condições de regularidade são válidas, temos que $\sqrt{n}(\hat{\mu}_n - \mu) \xrightarrow[n \rightarrow \infty]{D} N(0, \mu^3/\lambda)$.
- Assim, $IC(\mu, \gamma) = \left[\hat{\mu} - z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\mu}^3}{\lambda}}; \hat{\mu} + z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\mu}^3}{\lambda}} \right]$, em que $P(Z \leq z_{\frac{1+\gamma}{2}}) \approx \frac{1+\gamma}{2}$, $Z \sim N(0, 1)$.
- Um teste assintótico para testar $H_0 : \mu = \mu_0$ vs $H_0 : \mu \neq \mu_0$, é dado por:

$$\phi(t) = \begin{cases} 1, & \text{se } t < -c \text{ ou } t > c \\ 0, & \text{cc} \end{cases}$$

em que $t = \frac{\hat{\mu} - \mu_0}{\frac{\hat{\mu}^3}{n\lambda}}$, $P_{\mu_0}(T < c) = \frac{1+\gamma}{2}$ e $T = \frac{\hat{\mu} - \mu_0}{\sqrt{\frac{\hat{\mu}^3}{n\lambda}}} \approx N(0, 1)$, sob H_0 , para n suficientemente grande

Normal inversa (λ conhecido)

- Hipóteses: $H_0 : \mu = \mu_0$ vs $H_0 : \mu \neq \mu_0$
- TRV (versão assintótica). Lembre que $\hat{\mu}_0 = \mu_0$:

$$\begin{aligned}Q_{RV} &= 2(l(\hat{\mu}) - l(\hat{\mu}_0)) = \lambda \left(-\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{\bar{x}^2 x_i} + \sum_{i=1}^n \frac{(x_i - \mu_0)^2}{\mu_0^2 x_i} \right) \\&= \lambda \left(\sum_{i=1}^n x_i \left(\frac{1}{\mu_0^2} - \frac{1}{\bar{x}^2} \right) - 2 \sum_{i=1}^n \left(\frac{1}{\mu_0} - \frac{1}{\bar{x}} \right) \right) \\&= \lambda \left(\left(\frac{1}{\mu_0^2} - \frac{1}{\bar{x}^2} \right) n\bar{x} - 2n \left(\frac{1}{\mu_0} - \frac{1}{\bar{x}} \right) \right) \\&= \lambda \left[\frac{n}{\mu_0} \left(\frac{\bar{x}}{\mu_0} - 2 \right) + \frac{n}{\bar{x}} \right]\end{aligned}$$

Normal inversa (λ conhecido)

- Wald.

$$\begin{aligned}Q_{RV} &= \frac{(\hat{\mu} - \mu_0)^2}{\frac{\hat{\mu}^3}{n\lambda}} = \frac{n\lambda(\hat{\mu} - \mu_0)^2}{\hat{\mu}^3} = n\lambda \left(\frac{1}{\bar{X}} - 2\frac{\mu_0}{\bar{X}^2} + \frac{\mu_0^2}{\bar{X}^3} \right) \\ &= \frac{n\lambda\mu_0^2}{\bar{X}^3} \left(\frac{\bar{X}^2}{\mu_0^2} - 2\bar{X} + 1 \right)\end{aligned}$$

- Escore de Rao: $H_0 : g(\mu) = \mu - \mu_0 = 0$ vs $H_0 : g(\mu) = \mu - \mu_0 \neq 0$
(Lembre que $\hat{\mu}_0 = \mu_0$)

$$Q_S = \frac{S^2(\mu_0)}{I(\mu_0)} = \frac{\lambda^2 \left(\sum_{i=1}^n \frac{(x_i - \mu_0)}{\mu_0^3} \right)^2}{\frac{n\lambda}{\mu_0^3}} = \frac{n\lambda}{\mu_0} \left(\frac{\bar{X}}{\mu_0} - 1 \right)^2$$

Normal inversa (μ conhecido)

- Priori conjugada. Note que

$$L(\boldsymbol{\theta}) \propto \lambda^{n/2} \exp \left\{ -\frac{\lambda}{2\mu^2} \sum_{i=1}^n \frac{(x_i - \mu)^2}{x_i} \right\}$$
$$\rightarrow p(\lambda) \propto \lambda^{a-1} e^{-\lambda b}$$

- Assim, a priori conjugada é dada por $\lambda \sim \text{gama}(a, b^{-1})$.
- Portanto, a posteriori é dada por:

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

- Logo, $\lambda|\mathbf{x} \sim \text{gama}(a^*, (b^*)^{-1})$, em que $a^* = n/2 + a$,

$$b^* = b + \frac{1}{2\mu^2} \sum_{i=1}^n \frac{(x_i - \mu)^2}{x_i}$$

Normal inversa (μ conhecido)

- Estimador de Bayes sob perda quadrática:

$$\hat{\lambda}_{\text{Bayes}} = \mathcal{E}(\lambda|\mathbf{X}) = \frac{n + 2a}{\frac{1}{\mu^2} \sum_{i=1}^n \frac{(X_i - \mu)^2}{X_i} + 2b}$$

- Intervalo de Credibilidade. Do slides anterior, temos que $2b^* \lambda | \mathbf{x} \sim \chi_{2a^*}^2$. Assim,

$$\begin{aligned} P(q_1 < 2b^* \lambda < q_2 | \mathbf{x}) &= \gamma \\ P\left(\frac{q_1}{2b^*} < \lambda < \frac{q_2}{2b^*} | \mathbf{x}\right) &= \gamma \end{aligned} \quad (2)$$

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

Normal inversa (μ conhecido)

- Teste de hipótese (IB): $H_0 : \lambda \leq \lambda_0$ vs $H_1 : \lambda > \lambda_0$. Note que:

$$\begin{aligned}P(\lambda \in \Theta_0 | \mathbf{x}) \geq c &= P(\lambda \leq \lambda_0 | \mathbf{x}) \geq c \\&= P(2b^* \lambda \leq 2b^* \lambda_0 | \mathbf{x}) \geq c \\&\rightarrow 2b^* \lambda_0 \geq F_V^{-1}(c) \rightarrow b^* \geq \frac{F_V^{-1}(c)}{2b^*} \\&\rightarrow \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\mu^2 x_i} \geq \frac{F_V^{-1}(c)}{2b^*} - b\end{aligned}$$

- Assim, sendo $F_V(\cdot)$ é a fda de $V \sim \chi_{2a}^2$, temos que:

$$RC = \left\{ \mathbf{x} \in \mathfrak{R}^{+n} : \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\mu^2 x_i} \geq \frac{F_X^{-1}(c)}{2b^*} - b \right\}$$