

Lista 2 - Inferência Estatística

Livro Robert Keener

6. $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Beta}(\alpha, \beta)$

a) A densidade conjunta de uma amostra aleatória é

$$f_{\alpha, \beta}(\mathbf{x}) = \frac{1}{B(\alpha, \beta)^n} \left(\prod_{i=1}^n x_i \right)^{\alpha-1} \left(\prod_{i=1}^n (1-x_i) \right)^{\beta-1} \mathbb{1}_{\{0 \leq x_{(1)} \leq x_{(n)} \leq 1\}}$$

Pelo Teorema da Fatorização,

$$T(\mathbf{x}) = \left(\prod_{i=1}^n x_i, \prod_{i=1}^n (1-x_i) \right)$$

é estatística suficiente. Além disso, se $\mathbf{x}, \mathbf{y} \in (0, 1)^n$,

$$\frac{f_{\alpha, \beta}(\mathbf{x})}{f_{\alpha, \beta}(\mathbf{y})} = \left(\prod_{i=1}^n \frac{x_i}{y_i} \right)^{\alpha-1} \left(\prod_{i=1}^n \frac{1-x_i}{1-y_i} \right)^{\beta-1}$$

Para que essa razão não dependa de α

$$\frac{f_{2,1}(\mathbf{x})}{f_{2,1}(\mathbf{y})} = \prod_{i=1}^n \frac{x_i}{y_i} = 1 = \frac{f_{1,1}(\mathbf{x})}{f_{1,1}(\mathbf{y})} \Rightarrow \prod_{i=1}^n x_i = \prod_{i=1}^n y_i$$

Já para que não dependa de β ,

$$\prod_{i=1}^n \frac{1-x_i}{1-y_i} = 1 \Rightarrow \prod_{i=1}^n (1-x_i) = \prod_{i=1}^n (1-y_i)$$

o que implica que $T(\mathbf{x}) = T(\mathbf{y})$ e T é estatística suficiente mínima pelo Teorema de Lehmann-Scheffé.

b) Se $\alpha = 2\beta$, $T(\mathbf{x}) = \prod_{i=1}^n x_i^2 (1-x_i)$

é estatística suficiente mínima por Lehmann-Scheffé.

c) Se $\alpha = \beta^2$, temos o caso inicial (demonstração similar)

7. $X_1, \dots, X_n \sim \text{Bernoulli}(p_i)$ independentes, com
 $\log\left(\frac{p_i}{1-p_i}\right) = \alpha + \beta \cdot t_i$

A densidade conjunta é: $p_i = \exp(\alpha + \beta \cdot t_i)$

$$\begin{aligned} f_{\alpha, \beta}(x) &= \prod_{i=1}^n p_i^{x_i} (1-p_i)^{1-x_i} \\ &= \prod_{i=1}^n \frac{e^{(\alpha + \beta t_i) x_i}}{(1 + e^{\alpha + \beta t_i})^{x_i}} \frac{1}{(1 + e^{\alpha + \beta t_i})^{1-x_i}} \\ &= \frac{e^{\alpha \sum_{i=1}^n x_i + \beta \sum_{i=1}^n t_i x_i}}{\prod_{i=1}^n (1 + e^{\alpha + \beta t_i})} \rightarrow \text{só depende de } \alpha \text{ e } \beta. \end{aligned}$$

Note que essa densidade pertence à família exponencial com estatística suficiente

$$T(x) = \left(\sum_{i=1}^n x_i, \sum_{i=1}^n t_i x_i \right),$$

que é mínima, pois o espaço dos parâmetros \mathbb{R}_+^2 contém aberto.

9. Lista 1.

12. $Z_1, Z_2 \stackrel{iid}{\sim} \mathcal{N}(0, 1)$,
 $X = Z_1, Y = (Z_1 + Z_2)\theta$.

a) $\begin{bmatrix} X \\ Y \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ \theta & \theta \end{bmatrix} \begin{bmatrix} Z_1 \\ Z_2 \end{bmatrix}$, em que $(Z_1, Z_2) \sim \mathcal{N}(0, I_2)$.

Seja $A = \begin{bmatrix} 1 & 0 \\ \theta & \theta \end{bmatrix} \Rightarrow AA^T = \begin{bmatrix} 1 & 0 \\ \theta & \theta \end{bmatrix} \begin{bmatrix} 1 & \theta \\ 0 & \theta \end{bmatrix} = \begin{bmatrix} 1 & \theta \\ \theta & 2\theta^2 \end{bmatrix}$.

Portanto $(X, Y) \sim \text{Normal}\left(0, \begin{bmatrix} 1 & \theta \\ \theta & 2\theta^2 \end{bmatrix}\right)$

$\sigma_X = 1, \sigma_Y = \sqrt{2}\theta, \rho = 1/\sqrt{2}$

b) Seja a amostra $(X_1, Y_1), \dots, (X_n, Y_n)$.

$$f_{\theta}(x, y) = \frac{1}{(2\pi)^n \cancel{2^2} \theta^n \cancel{2^{-n/2}}} \exp \left\{ - \left[\sum x_i^2 - \frac{1}{\theta} \sum x_i y_i + \frac{1}{2\theta^2} \sum y_i^2 \right] \right\}$$

$$= e^{-\sum x_i^2} (2\pi\theta)^{-n} \exp \left\{ -\frac{1}{2\theta^2} \left[\sum_{i=1}^n y_i^2 - 2\theta \sum x_i y_i \right] \right\},$$

logo $T(x, y) = (\sum_{i=1}^n y_i^2, \sum x_i y_i)$ é estatística suficiente mínima por Lehmann-Scheffé. Basta ver que

$$\log \frac{f_{\theta}(x, y)}{f_{\theta}(\bar{x}, \bar{y})} = -\frac{1}{2\theta^2} \left[\sum y_i^2 - \sum \tilde{y}_i^2 - 2\theta (\sum x_i y_i - \sum \tilde{x}_i \tilde{y}_i) \right]$$

não depende de θ implica $\sum y_i^2 = \sum \tilde{y}_i^2$ e $\sum x_i y_i = \sum \tilde{x}_i \tilde{y}_i$.

15. Sabemos que se $x \sim N(\theta, 1)$,
 $E_{\theta}[g(x)] = 0 \Rightarrow g(x) = 0$ q.c.

Considere

$$\int f(x) e^{\theta x} = \sqrt{2\pi} e^{\theta^2/2}, \quad \theta \in \mathbb{R}$$

$$\Rightarrow \int \frac{1}{\sqrt{2\pi}} f(x) e^{\frac{x^2}{2}} e^{-\frac{x^2}{2} + \theta x - \frac{\theta^2}{2}} dx = 1, \quad \forall \theta \in \mathbb{R}$$

$$\Rightarrow \int \frac{1}{\sqrt{2\pi}} f(x) e^{\frac{x^2}{2}} e^{-\frac{1}{2}(x-\theta)^2} dx = 1, \quad \forall \theta \in \mathbb{R},$$

Com isso, como $\int \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\theta)^2} dx = 1$, temos que

$f(x) = e^{-\frac{x^2}{2}}$ é solução. Para a unicidade, suponha que existe outra solução $g(x)$. Assim,

$$\int f(x) e^{\theta x} dx = \int g(x) e^{\theta x} dx = \sqrt{2\pi} e^{\theta^2/2}$$

$$\Rightarrow \int (f(x) - g(x)) e^{\theta x} dx = 0, \quad \forall \theta \in \mathbb{R}$$

$$\Rightarrow \int (f(x) - g(x)) e^{\frac{x^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\theta)^2} dx = 0, \quad \forall \theta \in \mathbb{R}.$$

Pela completude $(f(x) - g(x))e^{x^2/2} = 0 \Rightarrow f = g$
quase sempre.

16. Lista 1.

Livro Casella Berbers

6.8. Já provamos na lista 1 que $T(X_1, \dots, X_n) = (X_{(1)}, \dots, X_{(n)})$ é estatística suficiente. Falta provar que é mínima, quando não há conhecimento adicional sobre f . Seja

$$f(x) = \frac{1}{\pi(1+x^2)}.$$

Assim para $x, y \in \mathbb{R}^n$,

$$\frac{\prod_{i=1}^n f(x_i - \theta)}{\prod_{i=1}^n f(y_i - \theta)} = \prod_{i=1}^n \frac{1 + (y_i - \theta)^2}{1 + (x_i - \theta)^2} = \prod_{i=1}^n \frac{1 + y_i^2}{1 + x_i^2}$$

não depende de θ . Defina o polinômio

$$p_x(\theta) = \prod_{i=1}^n \frac{\theta^2 - 2\theta x_i + x_i^2 + 1}{1 + x_i^2},$$

de ordem $2n$. Sabemos que ele tem $2n$ raízes da forma

$$x_j \pm i, \quad j = 1, \dots, n.$$

Como $p_x = p_y$, temos que eles tem as mesmas raízes, portanto $\forall i = 1, \dots, n, \exists j \in \{1, \dots, n\}$, tal que

$$x_i = y_j.$$

Logo $(X_{(1)}, \dots, X_{(n)}) = (Y_{(1)}, \dots, Y_{(n)})$ é estatística suficiente mínima para Cauchy, que pertence à família exponencial.

6.9. Up to you.

6.31. (a) Extra 1.

(b) Lista adicional

$$(c) \quad E[X^k] = E[(X/Y)^k Y^k] \\ = E[(X/Y)^k] E[Y^k] \\ \Rightarrow E[(X/Y)^k] = E[X^k] / E[Y^k], \text{ quando } E[Y^k] \neq 0.$$

Seja $X_1, \dots, X_n \sim \text{Gamma}(\alpha, \beta)$ e $T = \sum_j X_j$. Note que

$$f_{\beta}(x) = \frac{\beta^{n\alpha}}{\Gamma(\alpha)^n} \exp\{-\beta T\}$$

Logo T é estatística suficiente completa, pois f_{β} pertence à família exponencial. Lembra que $\beta^{-1} X_i \sim \text{Gamma}(\alpha, 1)$, logo a distribuição de $\beta^{-1}(X_1, \dots, X_n)$ não depende de β e, portanto, $\beta^{-1} X_{(i)}$ não depende de β . Mas

$$\frac{X_{(i)}}{T} = \frac{\beta^{-1} X_{(i)}}{\beta^{-1} T},$$

$\beta^{-1} T \sim \text{Gamma}(n\alpha, 1)$

que tem distribuição que não depende de β . Com isso $X_{(i)}/T$ é estatística ancilar. Pelo Teorema de Basu, T e $X_{(i)}/T$ são independentes. Logo

$$E[X_{(i)} | T] = E\left[\frac{X_{(i)}}{T} \cdot T | T\right] \\ = T \cdot E\left[\frac{X_{(i)}}{T} | T\right] \quad \rightarrow \text{independe de } T \\ = T \cdot \frac{E[X_{(i)}]}{E[T]} \quad \rightarrow \frac{X_{(i)}}{T} \perp T$$

Questões extras

$$1. \quad f_{\mu}(x) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\} \\ = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \left(\sum x_i^2 + n\mu^2\right) + \frac{\mu n \bar{x}}{\sigma^2}\right\},$$

logo, como pertence à família exponencial, \bar{x} é estatística

Suficiente completa para μ .

O resultado $\frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2_{n-1}$ é bastante conhecido.

Logo $S_n^2 \sim \text{Gamma}\left(\frac{n-1}{2}, \frac{\sigma^2}{2(n-1)}\right)$ não depende de μ e, portanto, é estatística auxiliar.

Concluimos, pelo Teorema de Basu, que \bar{X} e S_n^2 são independentes. Note que para cada σ^2 , \bar{X} é independente de S_n^2 , isto é,

$$f_{\bar{X}, S_n^2}(x, y | \mu, \sigma) = f_{\bar{X}}(x | \mu, \sigma) f_{S_n^2}(y | \mu, \sigma).$$

Logo, desconhecer σ não afeta essas distribuições.

2. Exercício 6.8

3. Vamos aplicar Lehmann-Scheffé. Seja $x, y \in \mathbb{R}^n$,

$$\begin{aligned} \log \frac{f_\theta(x)}{f_\theta(y)} &= - \sum_{i=1}^n |x_i - \theta| + \sum_{i=1}^n |y_i - \theta| \\ &= - \sum_{x_i \leq \theta} (\theta - x_i) - \sum_{x_i > \theta} x_i - \theta + \sum_{y_i \leq \theta} (\theta - y_i) + \sum_{y_i > \theta} (y_i - \theta) \\ &= \theta \sum_{i=1}^n \mathbb{1}\{x_i > \theta\} - \mathbb{1}\{x_i \leq \theta\} + \mathbb{1}\{y_i \leq \theta\} - \mathbb{1}\{y_i > \theta\} \\ &\quad + \sum_{i=1}^n (-1)^{\mathbb{1}\{x_i > \theta\}} x_i - (-1)^{\mathbb{1}\{y_i > \theta\}} y_i \\ &= 2\theta \sum_{i=1}^n \mathbb{1}\{x_i > \theta\} - \mathbb{1}\{y_i > \theta\} - n + \sum_{i=1}^n (-1)^{\mathbb{1}\{x_i > \theta\}} x_i - (-1)^{\mathbb{1}\{y_i > \theta\}} y_i \end{aligned}$$

não depende de θ . Seja $z_{(1)}, \dots, z_{(2n)}$ uma ordenação de x e y . Considere $i = \min \{j : z_{(j)} < z_{(j+1)}\}$. Se $z_{(i)} = z_{(i+1)}$, $\forall i$, temos que x e y têm a mesma estatística de ordem. Caso contrário, $i < 2n$. Faça $\theta \in (z_{(i)}, z_{(i+1)})$. Nesse intervalo, essa função só

não varia se $\sum_{i=1}^n \mathbb{1}\{x_i > \theta\} = \sum_{i=1}^n \mathbb{1}\{y_i > \theta\}$. Observe que isso deve ocorrer para todo intervalo, o que ocorre se as estatísticas de ordem de x e y são iguais. Logo, a estatística de ordem é suficiente mínima.

$$4. a) f_{\theta}(x_1, \dots, x_n) = \theta^{-2n} \exp \left\{ -\frac{1}{\theta^2} \sum_{i=1}^n (x_i - \theta) \right\} \mathbb{I}\{\min x_i > \theta\}$$

$$= \theta^{-2n} \exp \left\{ -\frac{n\bar{x}}{\theta^2} + \frac{1}{\theta} \right\} \mathbb{1}\{x_{(n)} > \theta\}$$

Denote $T(x) = (\bar{x}, x_{(n)})$. Suponha que

$$\log \frac{f_{\theta}(x)}{f_{\theta}(y)} = -\frac{n}{\theta^2} (\bar{x} - \bar{y})$$

não depende de θ . Assim fazendo $d/d\theta$, temos que

$$2n\theta^{-3}(\bar{x} - \bar{y}) = 0 \Rightarrow \bar{x} = \bar{y}$$

Suponha que $\min\{x_i\} > \min\{y_i\}$ e tome $\theta \in (\min y_i, \min x_i)$. Assim $\log f_{\theta}(x)/f_{\theta}(y)$ não está bem definido, o que é um absurdo. Com isso $x_{(n)} \leq y_{(n)}$. Analogamente $y_{(n)} \leq x_{(n)}$. Concluo que $T(x) = T(y)$ e T é estatística suficiente mínima.

b) Note que $X_i - \theta \sim \text{Exponencial}(\theta^2)$. Assim,

$$\frac{X_i - \theta}{\theta^2} \sim \text{Exp}(1), i=1, \dots, n$$

Portanto a distribuição de $(X_{(j)} - \theta)/\theta^2$ independe de θ .

Em particular, a distribuição de

$$\frac{X_{(n)} - X_{(1)}}{\bar{X} - X_{(1)}} = \frac{(X_{(n)} - \theta)/\theta^2 - (X_{(1)} - \theta)/\theta^2}{(\bar{X} - \theta)/\theta^2 - (X_{(1)} - \theta)/\theta^2}$$

não depende de θ . Se T fosse completo, por Basu,

$$E_{\theta} \left[\frac{X_{(n)} - X_{(1)}}{\bar{X} - X_{(1)}} \mid T \right] = \frac{1}{\bar{X} - X_{(1)}} E_{\theta} [X_{(n)}] - \frac{X_{(1)}}{\bar{X} - X_{(1)}},$$

isto é, $E_0[X_{(n)}] = E_0[X_{(n)} | T]$. Mas isso não é verdade, pois se $X_{(1)}$ for grande, $X_{(n)}$ também será.