

Monitoria 26/07/2022

- $y = f(x_1, \dots, x_n)$
 $f_{x|y}(x_1, \dots, x_n | y) = \frac{f_{x,y}(x_1, \dots, x_n)}{f_y(y)}, \quad y = f(x)$

- Teorema da Fatorização

$$f(x|\theta) = h(x) g(T|x)$$

- Rao-Blackwell (Rao Blackwellização)

Se U é estatística não viésada e T é suficiente

$$S(T) = E[U|T] = \int u f_{U|T}(u|t) du$$

↳ integrar

$$R(\theta, S) < R(\theta, U) \quad (\text{Perdas convexas})$$

- Lehmann-Scheffé

Se

$$T(x) = T(y) \Leftrightarrow f(x|\theta) = f(y|\theta) h(x,y), \forall \theta$$

então T suficiente mínima.

completa \Rightarrow completa limitada

16 Kolmogorov

Bahadur

Se T é suficiente completa (limitada), então T é suficiente mínima

Basu

Se T é estatística suficiente completa e U é anular então T é independente de U .

6.3)

$$\text{Var}(T+U) = \text{Var}(T) + \text{Var}(U)$$

$$E[T+U] = E[T] + E[U]$$

$$f_{T,U}(t,u) = f_T(t) f_U(u)$$

- $R(\theta, \phi) = \text{Var } \phi(x) + \text{Viés}(\phi(x))^2$

$$E[(\phi(X) - \theta)^2]$$

Funções de Risco \rightarrow Erro médio (em relação aos dados)

- UMVUE: $R(\theta, \phi) = \text{Var } \phi(x)$

$$\begin{array}{ccc} Y & \downarrow & \\ \text{Viés} = 0 & & \downarrow \\ \text{Varância mínima} & & \text{MSE} \end{array}$$

Lehmann-Scheffé: $\hat{\theta}$ não viésado, $\hat{\theta}$ só depende de T (estatística suficiente completa), então $\hat{\theta}$ é UMVUE.

\rightarrow não enviesada

$$\begin{aligned} S(T) &= E[U|T] \\ \Rightarrow \hat{\theta} &\text{ é UMVUE. } E[X] = E[E[X|Y]] \end{aligned}$$

- Método dos momentos

- Máxima Verossimilhança

Teorema da Invariância

Se $\hat{\theta}_{MLE}$ é MLE de θ , então $g(\hat{\theta}_{MLE})$ é MLE de $g(\theta)$.

MLE para família exponencial

• Informação de Fisher

$$I_X(\theta) = -E_\theta \left[\frac{d^2}{d\theta^2} \log f(x|\theta) \right]$$

Teorema

$$E_\theta \left[\frac{d}{d\theta} \log f(x|\theta) \right] = 0$$

Função score

Se ϕ não é viesado,
isso é 1.

• limite de Cramér-Rao

$$\text{Var}(\phi(x)) \geq \underbrace{\left(\frac{d}{d\theta} E_\theta(\phi(x)) \right)^2}_{I_X(\theta)}$$

Vale a igualdade se, e somente, $\phi(x) \in \frac{d}{d\theta} \log f(x|\theta)$

são linearmente relacionadas.

$$\frac{d}{d\theta} \log f(x|\theta) = a(\theta) \phi(x) + b(\theta)$$

Se $\phi(x)$ é não viesado e

$$\frac{d}{d\theta} \log f(x|\theta) = \pi(\theta) \phi(x) + b(\theta),$$

então $\phi(x)$ é UMVUE.

Koopman
4.28

$$f(x|\theta) = c(\theta) h(x) \exp\{\pi(\theta) \phi(x)\}$$

↳ família exponencial

Assintótica: $n \rightarrow \infty$

- Consistência: $\phi_n(x_n) \xrightarrow{P} \theta \Rightarrow \{\phi_n\}_{n \in \mathbb{N}} \text{ é consistente}, \forall \varepsilon > 0$
 $P(|\phi_n(x_n) - \theta| > \varepsilon) \xrightarrow{n \rightarrow \infty} 0$
 $P(|\phi_n(x_n) - \theta| \leq \varepsilon) \xrightarrow{n \rightarrow \infty} 1$

Lei dos Grandes Números:

$$\bar{X}_n \rightarrow E[X]$$

$$\begin{cases} \lim_{n \rightarrow \infty} \text{Var}(\phi_n) = 0 \Rightarrow E[(\phi_n - \theta)^2] \xrightarrow{n \rightarrow \infty} 0 \\ \lim_{n \rightarrow \infty} \text{Viés}(\phi_n) = 0 \end{cases}$$

(Chebychev)

$$P(|\phi_n - \theta| \geq \varepsilon) \leq \frac{E[(\phi_n - \theta)^2]}{\varepsilon^2} = \frac{\text{Var}(\phi_n) + \text{Viés}(\phi_n)^2}{\varepsilon^2} \xrightarrow{n \rightarrow \infty} 0$$

Teorema Central do Limite

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{D} N(0, \sigma^2)$$

- MLE (em geral) é consistente $\hat{\theta}_n \xrightarrow{P} \theta \sim I_X(\hat{\theta}_{MLE})^{-1}$
 $\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{D} N(0, I_X(\theta)^{-1})$
↳ Verossimilhança contínua

$$f(x|\theta) = h(x) c(\theta) \exp\left\{ R(\theta) \cdot T(x) \right\}$$

$$f(x|\eta) = h(x) c(\theta) \exp\left\{ \eta \cdot T(x) \right\} \rightarrow \text{natural canônica}$$

↓
parâmetro natural

Lista 2-Extra 1

$$\mathcal{P}_\sigma = \{ N(\mu, \sigma^2) : \mu \in \mathbb{R} \}$$

- \bar{X} é estatística suficiente e completa

$$f(x|\mu) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$$

$$= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{ -\frac{1}{2\sigma^2} \sum x_i^2 \right\} \exp\left\{ \frac{\mu}{\sigma^2} \sum x_i \right\} \exp\left\{ -\frac{n\mu^2}{2\sigma^2} \right\}$$

Parâmetro natural

$$= \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{n\mu^2}{\sigma^2}} e^{-\frac{1}{2\sigma^2} \sum x_i^2} \exp\left\{ \frac{\eta = R(\mu)}{\sigma^2} \bar{x} \right\}$$

$\eta = R(\mu) = \mu/\sigma^2$
 $\eta' = \frac{\eta \mu}{\sigma^2} \in \mathbb{R}$

Como $\mathbb{R} \subset (0, 1)$, que é aberto, \bar{X} é suficiente e completa.

$$E_\theta[\log(\bar{x})] = 0 \Rightarrow \eta = 0$$

- $(n-1) \frac{s^2}{\sigma^2} \sim \chi^2_{n-1} = \text{Gamma}\left(\frac{n-1}{2}, \frac{1}{2}\right)$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$x_i - \bar{x}$ Ancilar

$$x_i - \bar{x} \sim N(0, \frac{n-1}{n} \sigma^2)$$

$$E[x_i - \bar{x}] = E[x_i] - \frac{1}{n} \cdot \sum_{j=1}^n E[x_j] = \mu - \mu = 0$$

$$\text{Var}(x_i - \bar{x}) = \frac{n-1}{n} \sigma^2$$

$(x_i - \bar{x})^2$ não depende de μ

$\sum_{i=1}^n (x_i - \bar{x})^2$ não depende de μ

$\Rightarrow S^2$ não depende de $\mu \Rightarrow S^2$ é anciliar

$\begin{cases} S^2 \text{ é anciliar e } \bar{x} \text{ é suficiente completo, então} \\ \bar{x} \text{ e } S^2 \text{ são independentes} \end{cases}$

Para cada σ fixado, \bar{x} independe de S^2

$\forall \sigma, \forall \mu, \bar{x} \text{ e } S^2$ são independentes

+ Exercício Basu
6.36