

Lista 5

Robert Keener

9.1. $G_n(t) = n \sum_n (1-t)t^n - t$
 $g(t) = E[G_n(t)] = -t$

a) Fixe $t \in [0,1]$. Se $t=0,1$, $G_n(t) = -t$. Portanto,
 $G_n(t) - g(t) = 0, \forall n \in \mathbb{N} \Rightarrow G_n(t) \xrightarrow{P} g(t)$.
Se $t \in (0,1)$, quero mostrar que
 $n \sum_n (1-t)t^n \xrightarrow{P} 0$

Tome $\varepsilon > 0$. Assim,

$$\begin{aligned} P(|n \sum_n (1-t)t^n| > \varepsilon) &= P(|\sum_n| > \varepsilon t^{-n} / (1-t)_n) \\ &\leq (1-t)^2 n^2 t^{2n} / \varepsilon^2 \\ &\xrightarrow{n \rightarrow \infty} 0, \end{aligned}$$

visto que $\lim_{n \rightarrow \infty} n t^n = \lim_{x \rightarrow \infty} \frac{x}{t^{-x}} = -\lim_{x \rightarrow \infty} \frac{(\ln t)^{-1}}{t^{-x}} = 0$

Concluo que $G_n(t) \xrightarrow{P} g(t)$.

b) $\sup_{t \in [0,1]} n(1-t)t^n = n \max_{t \in [0,1]} (1-t)t^n$, pois $[0,1]$ é compacto.

Logo, existe máximo. Como não está nas extremidades, pois a função se anula lá, o máximo deve estar em $t^* \in (0,1)$:

$$\left. \frac{d}{dt} (1-t)t^n \right|_{t=t^*} = 0 \Rightarrow nt^{n-1} + (n+1)t^n = 0$$

$$\Rightarrow n + (n+1)t = 0$$

$$\Rightarrow t^* = n/(n+1)$$

$$\text{Logo } \sup n(1-t)t^n = \left(\frac{n}{n+1} \right)^{n+1} = \left(1 + \frac{1}{n} \right)^{-(n+1)} = e^{-1}$$

$$c) \|G_n - g\|_\infty = \sup_{t \in [0,1]} |n Z_n(1-t)t^n| \\ = |Z_n| \left(\frac{n}{n+1}\right)^{n+1} \xrightarrow{P} 0$$

$$d) P(|T_n| \leq \varepsilon) = P(G_n(t) \leq \varepsilon, \forall t \in [0,1]) \\ = P(|Z_n| \leq \varepsilon t^{-n} n^{-1} / (1-t), \forall t \in [0,1]) \\ \leq P(|Z_n| \leq e^{-1}) \rightarrow 1,$$

pois não depende de n .

9.2. Seja $\hat{\theta}_n = \mu^{-1}(X_n)$ e $\theta = \mu^{-1}(\mu(\varrho))$, que estão bem definidas pois μ é estritamente monótona, logo injetiva. Além disso, pelo Teorema da Função Inversa

$$\frac{d\mu^{-1}(\eta)}{d\eta} = \frac{1}{\mu'(\mu^{-1}(\eta))}.$$

Com isso, pelo método Delta,

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, \sigma^2(\theta) \cdot [\mu'^{-1}(\mu(\varrho))]^2),$$

que implica

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, \sigma^2(\theta) / \mu'(\varrho)^2)$$

$$9.3. \left| \int_0^1 [W_n(t) - f(t)] dt \right| \leq \int_0^1 |W_n(t) - f(t)| dt \\ \leq \|W_n - f\|_\infty \xrightarrow{P} 0$$

$$9.8. Sejam S_x^2 = \sum_{i=1}^m (x_i - \bar{x})^2 / (m-1), \\ S_y^2 = \sum_{i=1}^n (y_i - \bar{y})^2 / (n-1)$$

Sabemos que $(m-1)S_x^2 / \sigma_x^2 \sim \chi_{m-1}^2$
 $(n-1)S_y^2 / \sigma_y^2 \sim \chi_{n-1}^2$

Portanto,

$$F = \frac{S_y^2 / \sigma_y^2}{S_x^2 / \sigma_x^2} \sim F(n-1, m-1).$$

$$\begin{aligned} \text{Seja } 1-\alpha &= P(c_1 < F < c_2) \\ &= P\left(\frac{S_x^2 / S_y^2}{c_1} < \frac{\sigma_x^2 / \sigma_y^2}{c_2} < \frac{S_x^2 / S_y^2}{c_2}\right) \\ &= P\left(\sqrt{\frac{S_x^2}{S_y^2} c_1} < \frac{\sigma_x}{\sigma_y} < \sqrt{\frac{S_x^2}{S_y^2} c_2}\right) \end{aligned}$$

9.13. (X_i, Y_i) iid com $X_i \sim N(0, 1)$, $Y_i | X_i \sim N(X_i \theta, 1)$

$$\begin{aligned} f(x, y | \theta) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-\frac{x_i^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(y_i - \theta x_i)^2} \\ &= \frac{1}{(2\pi)^n} \exp\left\{-\frac{1}{2} \sum_{i=1}^n x_i^2 + (y_i - \theta x_i)^2\right\} \end{aligned}$$

\rightarrow log-verossimilhança

$$2) l(\theta | x, y) = -\frac{1}{2} \sum_{i=1}^n x_i^2 + (y_i - \theta x_i)^2 - n \log(2\pi).$$

Assim

$$\frac{d}{d\theta} l(\theta | x, y) = \sum_{i=1}^n (y_i - \theta x_i) x_i = 0$$

implica $\theta \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i y_i$ e, portanto,

$$\hat{\theta} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$$

e é único ponto crítico (com prob. 1).

$$\frac{d^2}{d\theta^2} l(\theta | x, y) = \sum_{i=1}^n -x_i^2 < 0$$

e, portanto, $\hat{\theta}$ é MLE para θ .

$$b) I(\theta) = -E_\theta \left[\frac{d^2}{d\theta^2} l(\theta | x_i, y_i) \right] = E[x_i^2] = 1, \quad \forall \theta \in \mathbb{R}$$

c) Vamos verificar as condições do Teorema 9.14

1. ✓

2. $A = \mathbb{R}^2$

3. $\partial^2 f_\theta(x, y) / \partial \theta^2$ existe e é contínua em θ .

4. A informação de Fisher existe.

5. Tome $\theta \in \mathbb{R}$,

$$\|1_{[\theta-\epsilon, \theta+\epsilon]} x^2\|_\infty = x^2 \Rightarrow E_\theta[x^2] < +\infty.$$

6. Temos, pela LGN,

$$\frac{1}{n} \sum_{i=1}^n x_i y_i \xrightarrow{P} E[XY]$$

$$\frac{1}{n} \sum_{i=1}^n x_i^2 \xrightarrow{P} \text{Var}(X) = 1. \text{ Com isso,}$$

$$\hat{\theta}_n \xrightarrow{P} E[XY] = E[X E[Y|X]] = \theta$$

pelo Teorema de Slutsky.

Com isso,

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, 1)$$

Obs.: O Teorema 7.57 do Schervish é mais direto para integrantes da Família Exponencial.

d) Seja c_1 e c_2 tal que

$$\Phi(c_2) - \Phi(c_1) = 1 - \alpha.$$

Assim,

$$P\left(\hat{\theta}_n - \frac{c_1}{\sqrt{n}} > \theta > \hat{\theta}_n - \frac{c_2}{\sqrt{n}}\right) = 1 - \alpha,$$

visto que

$$\sqrt{n}(\hat{\theta}_n - \theta) \approx N(0, 1).$$

e) A informação de Fisher observada é $-\frac{\partial^2}{\partial \theta^2} \ln(\theta | x, y) = \sum_{i=1}^n X_i^2$.
Nesse caso, o intervalo de confiança assintótico é dado por

$$\left(\hat{\theta}_n - c_2 / (\sum_{i=1}^n X_i^2)^{1/2}, \hat{\theta}_n - c_1 / (\sum_{i=1}^n X_i^2)^{1/2}\right),$$

Visto que

$$\sqrt{n I(\theta)} (\hat{\theta}_n - \theta) \xrightarrow{D} N(0, 1)$$

e $n I(\theta)$ é estimado por $\sum_{i=1}^n X_i^2$.

f) Note que

$$[\sum_{i=1}^n X_i^2]^{1/2}(\hat{\theta} - \theta) = \frac{\sum_{i=1}^n X_i Y_i - (\sum_{i=1}^n X_i^2)\theta}{[\sum_{i=1}^n X_i^2]^{1/2}}$$

Condicionado em X_1, \dots, X_n , $X_i Y_i \sim N(\theta X_i^2, X_i^2)$

Logo $\sum_{i=1}^n X_i Y_i \sim N(\theta \sum_{i=1}^n X_i^2, \sum_{i=1}^n X_i^2)$, que

implica que, condicionado em X_1, \dots, X_n ,

$$[\sum_{i=1}^n X_i^2]^{1/2}(\hat{\theta} - \theta) \sim N(0, 1).$$

Então,

$$\begin{aligned} P([\sum_{i=1}^n X_i^2]^{1/2}(\hat{\theta} - \theta) \leq x) &= E[P([\sum_{i=1}^n X_i^2]^{1/2}(\hat{\theta} - \theta) \leq x | X_1, \dots, X_n)] \\ &= E[\Phi(x)] \\ &= \Phi(x) \\ \Rightarrow [\sum_{i=1}^n X_i^2]^{1/2}(\hat{\theta} - \theta) &\sim N(0, 1). \end{aligned}$$

9.21. X_1, \dots, X_n iid com $f_\theta(x) = \theta e^{\theta x} / 2 \sinh \theta$, $x \in (-1, 1)$.
 $Y_i = \mathbb{1}\{X_i > 0\}$. Se $\theta = 0$, $X_i \sim U[-1, 1]$.

a) $l(\theta | x) = \begin{cases} n(\ln \theta - \ln(\sinh \theta)) + \theta \sum_{i=1}^n x_i - n \ln 2, & \theta \neq 0 \\ 0, & \theta = 0 \end{cases}$

Logo

$$\frac{d}{d\theta} l(\theta | x) = n \left(\frac{1}{\theta} - \frac{\cosh \theta}{\sinh \theta} \right) + \sum_{i=1}^n x_i^2 = 0$$

implica que $\hat{\theta}_x$ é solução de

$$\frac{1}{\theta} - \coth \theta = \bar{x}$$

ou $\hat{\theta}_x = 0$, dependendo do sinal de $l(\theta | x)$ se $\theta \neq 0$.

b) $Y_i \stackrel{\text{ind}}{\sim} \text{Bernoulli}(\text{P}(X_i > 0))$.

Se $\theta \neq 0$,

$$\text{P}_\theta(X_i > 0) = \int_0^1 \frac{\theta e^{\theta x}}{2 \sinh \theta} dx = \frac{e^\theta - 1}{2 \sinh \theta} = \frac{e^\theta - 1}{e^\theta + e^{-\theta}}$$

Se $\theta = 0$, $\text{P}(X_i > 0) = 1/2$.

Note que $\lim_{\theta \rightarrow 0} \frac{e^\theta - 1}{e^\theta + e^{-\theta}} = \lim_{\theta \rightarrow 0} \frac{e^\theta}{e^\theta + e^{-\theta}} = \frac{1}{2}$

Com isso, o MLE para $p = \text{P}(X_i > 0)$ é $\hat{p} = \bar{Y}$.

$$\begin{aligned} p &= \frac{e^\theta - 1}{e^\theta + e^{-\theta}} \Rightarrow \frac{p}{1-p} = \frac{1 - e^{-\theta}}{e^\theta - e^{-\theta}} = 1 - p \\ &\Rightarrow \theta = \log\left(\frac{p}{1-p}\right) \end{aligned}$$

e, pela invariância,
 $\hat{\theta}_y = \log\left(\frac{\bar{Y}}{1-\bar{Y}}\right)$

é MLE para θ .

9.33. $X_1, X_2, \dots \stackrel{\text{iid}}{\sim} Q_\theta$, $\theta \in \Omega \subseteq \mathbb{R}^p$.

a) $\sqrt{n} I(\theta)^{1/2} (\hat{\theta}_n - \theta) \Rightarrow N(0, I_p)$ pelo Teorema de Slutsky.

9.34. $X_1, X_2, \dots \stackrel{\text{iid}}{\sim} Q_\theta$, $\theta = (\beta, \lambda)$

a) Tome $x \in \mathbb{R}_+$. Quero provar que $\{F_{M_n}(x)\}_n$ é convergente.
 Note que, para $\epsilon > 0$,

$$P(\sqrt{n} \sqrt{(\hat{\theta}_n - \theta)} I(\theta)(\hat{\theta}_n - \theta) \xrightarrow{\text{Chebychev}} \sqrt{n} \epsilon) \leq 2/\epsilon^2 n \xrightarrow{n \rightarrow \infty} 0$$

Assim $(\hat{\theta}_n - \theta) I(\theta)(\hat{\theta}_n - \theta) \xrightarrow{P} 0$. Em particular,
 $\hat{\theta}_n \xrightarrow{P} \theta$.

Com isso, $I(\hat{\theta}_n) \xrightarrow{P} I(\theta)$ pelo teorema do mapeamento contínuo.

Pelo Teorema de Slutsky,

$$\sqrt{n} I(\hat{\theta}_n)^{1/2} (\hat{\theta}_n - \theta) \xrightarrow{D} N(0, I_2)$$

Note que $M_n = \|\sqrt{n} I(\hat{\theta}_n)^{1/2} (\hat{\theta}_n - \theta)\|_\infty$. Portanto, pelo mapeamento contínuo, $M_n \Rightarrow M = \max\{12_1, 1, 12_2, 1\}$, tal que $Z \sim N(0, I_2)$.

b) Seja $P(M \leq q) = 1 - \alpha$. Assim

$$1 - \alpha = P(M \leq q) = P(|Z_1| \leq q, |Z_2| \leq q) = (1 - 2\Phi(-q))^2$$

$$\Rightarrow q = -\Phi^{-1}\left(\frac{1 - \sqrt{1 - \alpha}}{2}\right)$$

c) Basta tomar

$$S = \left\{ \theta \in \Omega \mid \| \Phi^{1/2}(\hat{\theta}_n) \theta \| \in \|\Phi^{1/2}(\hat{\theta}_n) \hat{\theta}_n\|_\infty \pm \frac{q}{\sqrt{n}} \right\},$$

com q dado em b).

Casella e Berger

9.11. Lembrando que

$$F_T(t|\theta) = P_\theta(T \leq t)$$

Siga $C = \{t : \alpha_1 \leq F_T(t|\theta_0) \leq 1 - \alpha_2\}$. Quero mostrar que $P_{\theta_0}(T \notin C) = \alpha$, ou $P_{\theta_0}(T \in C) = 1 - \alpha$,

isto é,

$$P(\alpha_1 \leq F_T(T|\theta_0) \leq 1 - \alpha_2) = 1 - \alpha.$$

Note que $F_T(T|\theta_0) \sim \text{Unif}(0, 1)$

$$\begin{aligned} P(F_T(T) \leq x) &= P(T \leq Q_T(x)) \\ &= F_T(Q_T(x)) = x, \end{aligned}$$

em que Q_T é a função quartil

Com isso, $P(\alpha_1 \leq F_T(T|\theta_0) \leq 1 - \alpha_2) = 1 - \alpha_2 - \alpha_1 = 1 - \alpha$.

9.14. $X_1, \dots, X_n \sim N(\mu, \sigma^2)$

Desigualdade de Bonferroni

$$P(\bigcup_{i=1}^n E_i) \leq \sum_{i=1}^n P(E_i). \text{ Logo}$$

$$P(E_1 \cap E_2) \geq P(E_1) + P(E_2) - 1$$

a) Defina $E_1 = \left\{ \mu : -\frac{k_s}{\sqrt{n}} \leq \mu - \bar{x} \leq \frac{k_s}{\sqrt{n}} \right\}$

$$E_2 = \left\{ \sigma^2 : \frac{(n-1)s^2}{a} \leq \sigma^2 \leq \frac{(n-1)s^2}{b} \right\}$$

Fazendo $P(E_i) = 1 - \alpha/2$, temos que
 $P(E_1 \cap E_2) \geq 1 - \alpha$,
como desejado. Logo

$$k = t_{n-1, \alpha/4} \quad a = \chi^2_{n-1, 1-\alpha/4}, \quad b = \chi^2_{n-1, \alpha/4}$$

\hookrightarrow Olhe página 429 Casella \leftarrow Página 430

b) Note que trocamos a estatística S pelo valor desconhecido σ^2 . Com isso, basta escolhermos k de forma apropriada, lembrando que

$$\sqrt{n} \left(\frac{\bar{X} - \mu}{\sigma} \right) \sim N(0, 1).$$

Assim $K = \Phi^{-1}(\alpha/4)$.

