

Bayesovské metody 5- Testy

12. října 2020

Outline

1 Testy

Outline

1 Testy

Testování hypotéz

Připomeňme:

$\mathbf{X} = (X_1, \dots, X_n)^\top$ – hustota $r(\mathbf{x}|\theta)$ vzhledem k ν_n ,

$\theta = (\theta_1, \dots, \theta_k)^\top$ – parametr, $\theta \in \Theta$

$\pi(\theta|\mathbf{X})$ – aposteriorní hustota

$q(\theta)$ – apriorní hustota

$\mathcal{H}_0 : \theta \in \Theta_0$ versus $\mathcal{H}_1 : \theta \in \Theta_1$

$\Theta_0 \cap \Theta_1 = \emptyset$, $\Theta_0 \cup \Theta_1 \subseteq \Theta$

$d_i = \{\text{plati } \mathcal{H}_i\}$, $i = 0, 1$, $\mathcal{D} = \{d_0, d_1\}$

Typicky:

$$L(\theta, d_i) = 0, \quad \theta \in \Theta_i, \quad i = 0, 1$$

$$L(\theta, d_i) \geq 0, \quad \theta \notin \Theta_i, \quad i = 0, 1$$

Obvyklé typy ztrátových funkcí

$$L_*(\theta, d_i) = 0, \quad \theta \in \Theta_i, \quad i = 0, 1$$

$$L_*(\theta, d_i) = a_i, \quad \theta \notin \Theta_i, \quad i = 0, 1$$

$$L_{**}(\theta, d_i) = 0, \quad \theta \in \Theta_i, \quad i = 0, 1$$

$$L_{**}(\theta, d_i) = K_i d(\theta, \Theta_i), \quad \theta \notin \Theta_i, \quad i = 0, 1$$

kde $d(\theta, \Theta_i)$ je vzdálenost θ od Θ_i a $K_i > 0$ konstanty

Riziková funkce;

$$R_*(\theta, \delta) = a_0 P(\delta(\mathbf{X}) = d_0 | \theta), \quad \theta \in \Theta_1$$

$$= a_1 P(\delta(\mathbf{X}) = d_1 | \theta), \quad \theta \in \Theta_0$$

Bayesovská riziková funkce

$$\begin{aligned} \rho_*(q, \delta) &= a_0 E \left[\int_{\Theta_1} P(\delta(\mathbf{X}) = d_0 | \theta) q(\theta) d\lambda(\theta) \right] \\ &+ a_1 E \left[\int_{\Theta_0} P(\delta(\mathbf{X}) = d_1 | \theta) q(\theta) d\lambda(\theta) \right] \end{aligned}$$

Jednoduché vlastnosti pro lib. $\delta \in \Delta$

$$P(\delta(\mathbf{X}) = d_0 | \theta) + P(\delta(\mathbf{X}) = d_1 | \theta) = 1, \quad \text{pro vs. } \theta \in \Theta$$

$$\int_{\Theta_1} L_*(\theta, d_0) \pi(\theta | \mathbf{X}) d\lambda(\theta) = a_0 P(\theta \in \Theta_1 | \mathbf{X})$$

$$\int_{\Theta_0} L_*(\theta, d_1) \pi(\theta | \mathbf{X}) d\lambda(\theta) = a_1 P(\theta \in \Theta_0 | \mathbf{X})$$

Bayesovská rozhodovací funkce δ_*

$$\begin{aligned} \delta_*(\mathbf{X}) &= d_0 \quad \text{je-li} \quad P(\theta \in \Theta_1 | \mathbf{X}) < \frac{a_1}{a_0 + a_1}, \\ &= d_1 \quad \text{je-li} \quad P(\theta \in \Theta_1 | \mathbf{X}) > \frac{a_1}{a_0 + a_1}, \\ &= \text{lib.} \quad \text{je-li} \quad P(\theta \in \Theta_1 | \mathbf{X}) = \frac{a_1}{a_0 + a_1} \end{aligned}$$

Příklad, skripta str. 72 Doba čekání na autobus na zastávce má rovnoměrné rozdělení na $(0, \theta)$, $\theta > 0$, t.j. $r(x|\theta) = \theta^{-1}I\{x \in (0, \theta)\}$.

Testujeme $\mathcal{H}_0 : \theta \leq d$ proti $\mathcal{H}_1 : \theta > d$, kde $d > 0$ je dáno.

Apriorní konjugované rozdělení θ – Paretovo rozdělení s parametry (a, x_0) , tj.

$$q(\theta|a, x_0) = (a/x_0)(x_0/\theta)^{a+1}I\{\theta > x_0\}, \quad E\theta = ax_0(a-1)^{-1}$$

Aposteriorní rozdělení θ – Paretovo rozdělení s parametry $(a+n, \max_{i=0,1,\dots,n} x_i)$, tedy

$$\begin{aligned} P(\theta \leq d|\mathbf{X}) &= \int_0^d (n+a) \left(\max_{0 \leq i \leq n} X_i \right)^{a+n} \theta^{-a-1-n} I\{\theta > \max_{0 \leq i \leq n} X_i\} d\theta \\ &= 1 - \left(\max_{0 \leq i \leq n} X_i/d \right)^{a+n}, \quad d > \max_{0 \leq i \leq n} X_i, \\ &= 0, \quad d < \max_{0 \leq i \leq n} X_i. \end{aligned}$$

Při $L_*(\theta, \delta(\mathbf{X}))$ s $a_1 = a_0 > 0$ je bayes. rozhodovací funkce

$$\delta_*(\mathbf{X}) = d_1 \quad \text{pro} \quad P(\theta \leq d|\mathbf{X}) < P(\theta > d|\mathbf{X})$$

$$\delta_*(\mathbf{X}) = d_0 \quad \text{pro} \quad P(\theta \leq d|\mathbf{X}) > P(\theta > d|\mathbf{X})$$

$$= \text{lib.}, \quad \text{pro} \quad P(\theta \leq d|\mathbf{X}) = P(\theta > d|\mathbf{X})$$

Prosim dopocitat pro hodnoty ze skript str. 74, nahore, tedy

$$d = 15, \quad x_0 = 5, \quad a = 3, \quad \max(x_1, \dots, x_5) = 14$$

Jake bude rozhodnuti pri $L_*(\cdot, \cdot)$, $a_0 = a_1$?

Uvažujme nyní $L_{**}(\theta, d)$ pro

$$\mathcal{H}_0 : \theta \leq \theta_0, \quad \text{versus} \quad \mathcal{H}_1 : \theta > \theta_0$$

$$\begin{aligned} L_{**}(\theta, d_0) &= 0, & \theta \leq \theta_0 \\ &= \theta - \theta_0, & \theta > \theta_0 \end{aligned}$$

$$\begin{aligned} L_{**}(\theta, d_1) &= \theta_0 - \theta, & \theta \leq \theta_0 \\ &= 0, & \theta > \theta_0 \end{aligned}$$

Bayesovská rozhodovací funkce

$$\begin{aligned} \delta_{**}(\mathbf{X}) &= d_0 & E(\theta|\mathbf{X}) \leq \theta_0 \\ &= d_1 & E(\theta|\mathbf{X}) > \theta_0 \end{aligned}$$

Odvození

$$E(L_{**}(\theta, \delta(\mathbf{X}))|\mathbf{X}) = \int_{\theta_0}^{\infty} (\theta - \theta_0)\pi(\theta|\mathbf{X})d\lambda(\theta), \quad \delta(\mathbf{X}) = d_0$$

$$E(L_{**}(\theta, \delta(\mathbf{X}))|\mathbf{X}) = \int_0^{\theta_0} (\theta_0 - \theta)\pi(\theta|\mathbf{X})d\lambda(\theta), \quad \delta(\mathbf{X}) = d_1$$

Je-li

$$\int_{\theta_0}^{\infty} (\theta - \theta_0)\pi(\theta|\mathbf{X})d\lambda(\theta) \leq \int_0^{\theta_0} (\theta_0 - \theta)\pi(\theta|\mathbf{X})d\lambda(\theta)$$

pak bayesovské rozhodnutí je d_0 .

Testy při $\lambda(\Theta_0) = 0$

Nutné modifikovat buď hypotézy nebo apriorní rozdělení $q(\theta)$, popř. obojí.

$\lambda(\Theta_0) = 0$ implikuje $P(\theta \in \Theta_0) = 0$

(i) Hypotézy

$$\mathcal{H}_0 : \theta \in \Theta_0 \quad \text{versus} \quad \mathcal{H}_1 : \theta \in \Theta_1 = \Theta - \Theta_0$$

modifikujeme

$$\mathcal{H}_0^* : \theta \in \Theta_0^* \quad \text{versus} \quad \mathcal{H}_1 : \theta \in \Theta_1^* = \Theta - \Theta_0^*$$

$$0 < P(\theta \in \Theta_0^*) < 1, \quad \Theta_0 \subset \Theta_0^*$$

(ii) modifikujeme původní apriorní rozdělení $q(\cdot)$ následovně:

$$P(\theta \in \Theta_0) = a \in (0, 1), \quad P(\theta \in B) = (1 - a) \int_B q(\theta) d\lambda(\theta), \quad B \subseteq \Theta_0,$$

Příklad 1 Test IQ dítěte $\mathcal{H}_0 : \theta = 100$ versus $\mathcal{H}_1 : \theta \neq 100$

X má $N(\theta, 100)$, θ má $N(100, 225)$

$$P(\theta = 100) = 0$$

(i) změníme hypotézy $\mathcal{H}_0^* : \theta \in (100 - a, 100 + a)$ versus

$\mathcal{H}_1^* : |\theta - 100| > a \neq (100 - a, 100 + a)$, volíme $a > 0$

(ii) změním apriorní rozdělení zvolíme $q \in (0, 1)$ a $P(\theta = 100) = q$ a pro $B \subseteq \mathcal{R} - \{100\}$

$$P(\theta \in B) = (1 - q) \int_B q(\theta) d\lambda(\theta) \text{ volíme } q \in (0, 1)$$

Pak

$$P(\theta = 100|X) = \frac{qr(x|\theta = 100)}{qr(x|\theta = 100) + (1 - q) \int_B r(x|\theta)q(\theta)d\lambda(\theta)}$$

$$P(\theta \in B|X) = \frac{(1 - q) \int_B r(x|\theta = 100) + \int_B r(x|\theta)q(\theta)d\lambda(\theta)}{qr(x|\theta = 100) + (1 - q) \int_B r(x|\theta)q(\theta)d\lambda(\theta)}$$

Lindleyův paradox – při nevhodné volbě q dostaneme podivné závěry = detaily ve skriptech na str.78 a též v různých knihách a článcích

Příklad 1, pokrač. IQ dítěte, úloha diskriminace mezi hypotézami:

$$\mathcal{H}_1 : \theta \leq 90, \quad \mathcal{H}_2 : 90 < \theta < 110, \quad \mathcal{H}_3 : \theta \geq 110$$

Ztrátová funkce:

$$\begin{aligned} L(\theta, d_1) &= 0 & \theta \leq 90 \\ &= \theta - 90, & 90 < \theta < 110 \\ &= 2(\theta - 90) & \theta \geq 110 \end{aligned}$$

$$\begin{aligned} L(\theta, d_2) &= 90 - \theta & \theta \leq 90 \\ &= 0, & 90 < \theta < 110 \\ &= \theta - 90 & \theta \geq 110 \end{aligned}$$

$$\begin{aligned} L(\theta, d_3) &= 2(110 - \theta) & \theta \leq 90 \\ &= 110 - 90, & 90 < \theta < 110 \\ &= 0 & \theta \geq 110 \end{aligned}$$

Přímý výpočet pro lib. rozhodovací fci $\delta(x)$

$$E(L(\theta, \delta(X)|X = x)) = \int_{90}^{110} (\theta - 90)\pi(\theta|x)d\theta + 2 \int_{110}^{\infty} (\theta - 90)\pi(\theta|x)d\theta, \quad \delta(x) = d_1$$

$$E(L(\theta, \delta(X)|X = x)) = \int_{-\infty}^{90} (90 - \theta)\pi(\theta|x)d\theta + \int_{110}^{\infty} (\theta - 90)\pi(\theta|x)d\theta, \quad \delta(x) = d_2$$

$$E(L(\theta, \delta(X)|X = x)) = 2 \int_{-\infty}^{90} (110 - \theta)\pi(\theta|x)d\theta + 2 \int_{90}^{110} (110 - \theta)\pi(\theta|x)d\theta, \quad \delta(x) = d_3$$

pro $x = 115$ je

$$\begin{aligned} E(L(\theta, \delta(X)|X = 115) = 34,32 \quad \delta(115) = d_1, \\ - = 3,55 \quad \delta(115) = d_2, \\ = 3,24 \quad \delta(115) = d_3 \end{aligned}$$

Tedy bayesovské rozhodnutí je d_3 .

$$\begin{aligned} P(\theta \leq 90|x = 115) = 0,005 \quad P(90 \leq \theta \leq 110|x = 115) = 0,475 \\ P(\theta \geq 110|x = 115) = 0,520 \end{aligned}$$

Tím končí úvodní kapitoly do tzv. bayesovské statistiky. Snaha byla vysvětlit základní principy bayesovského uvažování a na příkladech ukázat možnosti využití. V kapitolách o odhadech a testech se výklad soustředil na konstrukce založené a statistických rozhodovacích funkcích. Samozřejmě lze aplikovat např. metodu maximální věrohodnosti či metodu podílem věrohodností založená na aposteriorních rozděleních.