

Bayesovské metody 4- Odhady

6. října 2020

Outline

Bayesovské
metody
4 -
Odhady

Outline

Odhady

1 Odhady

Outline

Bayesovské
metody
4 -
Odhady

Outline

Odhady

1 Odhady

Bodové odhady

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

Úloha bodu odhadu parametru θ lze formulovat jako statistický rozhodovací problém (Θ, \mathcal{D}, R) , kde $\mathcal{D} = \Theta$

$\delta(\mathbf{X})$ – odhad parametru θ

$L(\theta, \delta(\mathbf{X}))$ – ztrátová funkce

$R(\theta, \delta) = E(L(\theta, \delta(\mathbf{X}))|\theta)$ — riziková fce

$E(R(\theta, \delta))$ — bayesovská riziková fce

bayesovska rozhodovací fce $\delta_*(\mathbf{x})$ minimalizuje

$$\int_{\Theta} L(\theta, \delta(\mathbf{x}))\pi(\theta|\mathbf{x})d\lambda(\theta)$$

vzhledem k $\delta(\mathbf{x})$

Odhady, jednorozměrný případ

Typicky:

$$L_{a,w}(\theta, \delta(\mathbf{x})) = w(\theta)|\theta - \delta(\mathbf{x})|^a, \quad \theta \in \Theta, \quad \delta \in \Delta,$$

$w(\theta)$ – nezáporná měřitelná funkce, často hustota popř. $w(\theta) \equiv 1$

$a > 0$ – nejčastěji $a = 1$ nebo 2

Bayesovska rozhodovací fce (odhad) $\delta_{a,w}(\mathbf{x})$ minimalizuje

$$\int_{\Theta} |\theta - \delta(\mathbf{x})|^a w(\theta) \pi(\theta|\mathbf{x}) d\lambda(\theta) = \int_{\Theta} |\theta - \delta|^a \pi_1(\theta|\mathbf{x}) d\lambda(\theta) \times \frac{r_1(\mathbf{x})}{r(\mathbf{x})}$$

$$q_1(\theta) = \frac{q(\theta)w(\theta)}{\int_{\Theta} q(\theta)w(\theta)d\theta}, \quad \pi_1(\theta|\mathbf{x}) = \frac{r(\mathbf{x}|\theta)q_1(\theta)}{r_1(\mathbf{x})},$$

$$r_1(\mathbf{x}) = \int_{\Theta} r(\mathbf{x}|\theta)q_1(\theta)d\lambda(\theta)$$

q_1, π_1, r_1 — nové hustoty, vhodné pro výpočet

pro $a = 2$ je $E(|\theta - \delta(\mathbf{X})|^2 | \mathbf{X} = \mathbf{x})$ minimum vzhledem k $\delta(\mathbf{X})$ je dosaženo pro

$$\delta(\mathbf{X}) = E(\theta|\mathbf{X})$$

poznámka – $\min_a E(Y - a)^2$ je dosaženo pro $a = EY$

Řešení pro w obecné a $a = 2$:

$$\delta_{2,w}(\mathbf{x}) = \frac{\int_{\Theta} \theta \pi_1(\theta|\mathbf{x}) d\lambda(\theta)}{\int_{\Theta} \pi_1(\theta|\mathbf{x}) d\lambda(\theta)} = E_1(\theta|\mathbf{x})$$

$\rho_{w,2}^*(\mathbf{x}) = E_1(\text{var}_1(\theta|\mathbf{x}))$ – bayesovské riziko

předpoklady: $0 < \int_{\Theta} \theta^2 \pi_1(\theta|\mathbf{x}) < \infty$

Řešení pro w obecné a $a = 1$ je $\delta_{1,w}(\mathbf{x})$ – median aposteriorního rozdělení π_1

Příklad 1, pokračování. Problém určení IQ sledovaného dítěte.

Výsledek testu X má rozdělení $N(\theta, 100)$, θ má rozd. $N(100, 225)$

Aposteriorní rozdělení θ při daném X je normální

$$N\left(X \frac{225}{225 + 100} + 100 \frac{100}{225 + 100}, 69, 23\right)$$

Pro ztratovou funkci $L(\theta, \delta(x)) = (\theta - \delta(x))^2 \exp\{\frac{1}{2r}(\theta - 100)^2\}$, $r > 225$ dáváme větší váhu hodnotám θ dále od 100

Pak apriorní rozdělení $q_1(\theta)$ je $N\left(100, \left(\frac{1}{225} - \frac{1}{r}\right)^{-1}\right)$

a aposteriorní $\pi_1(\theta|x)$ je

$$N\left(x \frac{225r}{225r+100(r-225)} + 100 \frac{100(r-225)}{225r+100(r-225)}, \frac{100 \cdot 225r}{225r+100(r-225)}\right)$$

a dostaneme bayesovskou rozhodovací fci, tj. odhad θ :

$$\delta_{2,w}(x) = x \frac{225r}{225r + 100(r - 225)} + 100 \frac{100(r - 225)}{225r + 100(r - 225)}$$

porovnáme-li ji s odhadem θ pro $w(\theta) = 1$: $\delta_{1,2}(x)$

pak pro $x < 100$ je $\delta_{2,w}(x) < \delta_{1,2}(x)$ a pro $x > 100$ je $\delta_{2,w}(x) > \delta_{1,2}(x)$

Příklad Úkolem dvou fyziků je odhadnout jistou fyzikální konstantu θ .

1. fyzik vyjádří představu (apriorní rozdělení) parametru $\theta - N(900, 400)$
 2. fyzik vyjádří představu (apriorní rozdělení) parametr $\theta - N(800, 6400)$
- výsledek pokusu $X - N(\theta, 1600)$

$$1. \text{ fyzik aposteriorní rozdělení} - N\left(\frac{x+3600}{5}, 320\right), \quad N\left(\frac{\bar{x}_n+3600/n}{1+4/n}, \frac{1600}{n+4}\right)$$

$$2 \text{ fyzik aposteriorní rozdělení} - N\left(\frac{4x+800}{5}, 1750\right), \quad N\left(\frac{4\bar{x}_n+800/n}{4+1/n}, \frac{6400}{4n+1}\right)$$

opakuje se pokus nezávisle n krát

Příklad Empirické bayesovské postupy. X má Poissonovo rozdělení s parametrem $\lambda > 0$, z minulosti Y_1, \dots, Y_N nezávislé, Y_i má Poissonovo rozdělení s par. λ_i , $\lambda_1, \dots, \lambda_N$ nezávislé stejně rozdělené s hustotou $q(\cdot)$

Nejprve předpokládejme že λ_i má rozdělení gama (α, β) , $\alpha > 0, \beta > 0$

Pak pro nepodmíněnou střední hodnotu a nepodmíněný rozptyl náhodné veličiny Y_i

$$EY_i = E\lambda_i = \beta/\alpha, \quad \text{var}\{Y_i\} = E\lambda_i + E\left(\lambda_i - \beta/\alpha\right)^2 = (\beta/\alpha)(\alpha + 1)$$

$$\hat{\alpha} = \frac{\bar{Y}}{\hat{\sigma}^2 - \bar{Y}}, \quad \hat{\beta} = \frac{\bar{Y}^2}{\hat{\sigma}^2 - \bar{Y}}, \quad \text{je-li } \hat{\sigma}^2 - \bar{Y} > 0$$

kde $\hat{\sigma}^2 = \sum_i (Y_i - \bar{Y})^2 / (N - 1)$

Odhad λ při kvadratické ztrátové fci je $\hat{\lambda} = \frac{\hat{\beta} + x}{1 + \hat{\alpha}}$, je-li $\hat{\sigma}^2 - \bar{Y} > 0$

Jiný postup– pro obecnou apriorní hustotu $q(\cdot)$ při kvadratické ztrátové funkci má odhad θ tvar

$$\tilde{\lambda} = \frac{\int_0^\infty \lambda r(x|\lambda) q(\lambda) d\lambda}{\int_0^\infty \lambda r(x|\lambda) q(\lambda) d\lambda} = \frac{(x+1)r(x+1)}{r(x)}$$

$r(x) = P(X = x)$, což lze odhadnout $\hat{r}(x) = (\text{pocet } Y_i = x) / N$ a tedy máme nový odhad

$$\tilde{\lambda} \approx \frac{(x+1)\hat{r}(x+1)}{\hat{r}(x)}$$

vhodne jen pro velka N , jinak znacne nestabilni

Odhady, vícerozměrný případ

Ztrátová funkce

$$L_{\mathbf{A}}(\boldsymbol{\theta}, \boldsymbol{\delta}(\mathbf{X})) = (\boldsymbol{\theta} - \boldsymbol{\delta}(\mathbf{X}))^{\top} \mathbf{A}(\boldsymbol{\theta} - \boldsymbol{\delta}(\mathbf{X})),$$

\mathbf{A} – symetrická pozitivně semidefinitní matice typu $k \times k$

$\boldsymbol{\delta}(\mathbf{X}) = (\delta(\mathbf{X}), \dots, \delta(\mathbf{X}))^{\top}$ odhad parametru $\boldsymbol{\theta}$

Jsou-li prvky varianční matice $\text{var}\{\mathbf{X}|\boldsymbol{\theta}\}$ konečné, bayesovská optimální rozhodovací funkce $\boldsymbol{\delta}_{\mathbf{A}}^*(\mathbf{X})$ splňuje

$$(E(\boldsymbol{\theta}|\mathbf{X}) - \boldsymbol{\delta}_{\mathbf{A}}^*(\mathbf{X}))^{\top} \mathbf{A}(E(\boldsymbol{\theta}|\mathbf{X}) - \boldsymbol{\delta}_{\mathbf{A}}^*(\mathbf{X})) = 0$$

a bayesovské riziko je

$$\rho_{\mathbf{A}}^*(q) = E\{\text{tr}\{\mathbf{A} \text{var}(\boldsymbol{\theta})\}\} \cdot \int_{\Theta} r(\mathbf{X}|\boldsymbol{\theta})q(\boldsymbol{\theta})d\lambda(\boldsymbol{\theta})$$

O platnosti se lze přesvědčit vhodnou úpravou

$$\int_{\Theta} r(\mathbf{X}|\boldsymbol{\theta})q(\boldsymbol{\theta})(\boldsymbol{\theta} - \boldsymbol{\delta}(\mathbf{X}))^{\top} \mathbf{A}(\boldsymbol{\theta} - \boldsymbol{\delta}(\mathbf{X}))d\lambda(\boldsymbol{\theta})$$

Příklad Jsou-li X_i , $i = 1, \dots, n$ nezávislé a X_i rozdělení $N(\mu, \sigma^2)$, pak konjugované rozdělení parametrů μ , σ^{-2} je normální-gama rozdělení:

μ podmíněno σ^{-2} je $N(a, \sigma^2/r)$,

σ^{-2} má gama rozdělení (c, d) ,

parametry (a, r, c, d) , $a \in \mathcal{R}_1$, $r > 0$, $2d = 1, 2, \dots, d > 0$

aposteriorní rozdělení je normální-gama $\mu^*, r + n, c^*, d + n/2$)

$$\mu^* = \frac{ra + n\bar{x}_n}{n + r}, \quad c^* = c + \frac{1}{2} \sum_i (x_i - \bar{x}_n)^2 + \frac{rn(\bar{x}_n - a)^2}{2(r + n)}, \quad \bar{x}_n = \sum_i x_i/n.$$

Při ztrátové funkci $L_A(.,.)$ s \mathbf{A} lib.sym., pozitivně definit. jsou odhady μ a σ^{-2} :

$$\hat{\mu} = \frac{ra + \sum_i X_i}{r + n}, \quad \widehat{\sigma^{-2}} = \frac{d + n/2}{c + \frac{1}{2} \sum_i (X_i - \bar{X}_n)r + \frac{rn(\bar{X}_n - a)^2}{2(r+n)}}$$

Pro $r = 0$, $c = 0$, $d = -1/2$ dostaneme klasické odhady.

$\frac{\mu - \hat{\mu}}{(d+n/2)r/c^*}$ má t -rozdělení o $2(d + n/2)$ stupních volnosti

maximálně věrohodný odhad parametru σ^{-2} je založený na aposteriorní

$$\frac{d + n/2 - 1}{c + \frac{1}{2} \sum_i (X_i - \bar{X}_n)r + \frac{rn(\bar{X}_n - a)^2}{2(r+n)}}$$

Věrohodnostní množiny

Věrohodnostní množiny jsou bayesovskou analogií konfidenčních množin (oblastí) či intervalů při klasickém přístupu. Pozor na nejednotnou českou terminologii!

Konfidenční oblast pro parametr θ s koeficientem spolehlivosti $1 - \alpha$ – je definovaná jako borelovská množina $D_\alpha(\mathbf{X}) \subseteq \Theta$ s vlastností

$$P(\theta \in D_\alpha(\mathbf{X})|\theta) = 1 - \alpha, \quad \text{pro vs. } \theta \in \Theta,$$

t.j. $D_\alpha(\mathbf{X})$ pokrývá skutečnou hodnotu parametru θ s pravděpodobností $1 - \alpha$.

Při bayesovském přístupu – **100(1 - α)% věrohodnostní množina** (credible region v angličtině) parametru θ je definovaná ako borelovská množina $C_\alpha(\mathbf{X}) \subseteq \Theta$ s vlastností

$$P(\theta \in C_\alpha(\mathbf{X})|\mathbf{X}) = \int_{C_\alpha(\mathbf{X})} \pi(\theta|\mathbf{X}) d\lambda\theta = 1 - \alpha,$$

pravděpodobnost, že θ náleží do $C_\alpha(\mathbf{X})$ je $1 - \alpha$; $1 - \alpha$ se nazývá **věrohodnost**.

Snaha zkonstruovat $C_\alpha(\mathbf{X})$ s co nejmenším obsahem:

$$C_\alpha^*(\mathbf{X}) = \{\theta; \pi(\theta|\mathbf{X}) \geq k_\alpha\}$$

s vlastností $\int_{C_\alpha^*(\mathbf{X})} \pi(\theta|\mathbf{X}) d\lambda(\theta) = 1 - \alpha, \quad \int_{C_\alpha^*(\mathbf{X})} d\lambda(\theta) \leq \int_{C_\alpha(\mathbf{X})} d\lambda(\theta)$

Příklad 1, pokrač. Chceme zkonstruovat 95% verohodný interval pro kvocient inteligence θ . Aposteriorní rozdělení je $N(x \frac{225}{325} + 100 \frac{100}{325}, 69, 23)$. Tedy nejkratší 95% verohodný interval pro θ je

$$(x \frac{225}{325} + 100 \frac{100}{325} - 16,3, x \frac{225}{325} + 100 \frac{100}{325} + 16,3)$$

Klasický 95% interval spolehlivosti je $(x - 19,6, x + 19,6)$.

Příklad X_1, \dots, X_n je náh. výběr z $N(\mu, \sigma^2)$, $\mu, \sigma^{-2} > 0$ neznáme. Apriorní rozdělení parametrů μ, σ^{-2} je gama-normální (a, r, c, d)

Pak aposteriorní rozdělení μ, σ^{-2} je gama-normální (μ^*, r^*, c^*, d^*) a aposteriorní rozdělení $(\mu - \mu^*)(d^*, r/c^*)^{1/2}$ je t-rozdělení s $2d^*$ stupni volnosti, kde

$$\mu^* = \bar{x}_n \frac{n}{n+r} + a \frac{r}{n+r},$$

$$c^* = c + \frac{1}{2} \sum_i (x_i - \bar{x}_n)^2 + \frac{rn(\bar{x}_n - a)^2}{2(r+n)}$$

$$d^* = d + n/2$$

nejkratší 95% věrohodný interval pro μ má tvar

$$\left(\mu^* - t_{1-\alpha/2}(2d^*) \left(c^* (d^* r)^{-1} \right)^{1/2}, \mu^* + t_{1-\alpha/2}(2d^*) \left(c^* (d^* r)^{-1} \right)^{1/2} \right)$$

$t_{1-\alpha/2}(2d^*)$ je $100(1 - \alpha/2)\%$ kvantil t- rozdělení o $2d^*$, interval je nejkratší

marginální aposteriorní rozdělení σ^{-2} je gama rozdělení s parametry (c^*, d^*) , které je jednovrcholové, ale ne symetrické, maximálně věrohodný odhad zal.na aposteriorním rozdělení je $\hat{\sigma}^{-2} = (d^* - 1)/c^*$

podobně jako při klasickém přístupu se neužívá nejkratší maximalně věrohodný interval pro σ^{-2}

Pro $r \rightarrow 0$, $c \rightarrow 0$, $d \rightarrow -1/2$ dostaneme $c^* = \frac{1}{2}S_n^2$, $d^* = (n - 1)/2$ a 95% věrohodný interval pro μ má tvar

$$(\bar{X}_n - t_{1-\alpha/2}(n-1)S_n/\sqrt{n}, \bar{X}_n + t_{1-\alpha/2}(n-1)S_n/\sqrt{n})$$

$$S_n^2 = \frac{1}{n-1} \sum_i (X_i - \bar{X}_n)^2$$

a 95% věrohodný interval pro σ^2 má tvar

$$(S_n^2(n-1)/\chi_{1-\alpha/2}^2, S_n^2(n-1)/\chi_{\alpha/2}^2)$$

$\chi_{\alpha/2}^2(n-1)$ -kvantil χ^2 -rozdělení o $n-1$ stupních volnosti

Tedy bayesovské věrohodnostní intervaly spolehlivosti a klasické intervalové odhady se shodují.