

Bernstein-von-Mises

13. prosince 2020

- 1 Opakování z předchozího

- 1 Opakování z předchozího

Obecná Bayesova věta

$\theta = (\theta_1, \dots, \theta_k)^\top$ – náhodný vektor s hustotou $q(\theta)$ vzhl. k σ - konečné míře λ na $(\Theta, \mathcal{B}(\Theta))$, Θ - neprázdná borelovská podmnožina \mathcal{R}^k ,
 $\mathcal{B}(\Theta)$ – borelovské podmnožiny Θ

$\mathbf{X} = (X_1, \dots, X_n)^\top$ – náhodný vektor s podmíněnou hustotou $r(\mathbf{x}|\theta)$ při daném θ vzhl. k σ -konečné míře ν_n na $(\mathcal{R}^n, \mathcal{B}^n)$, tj.

$$P(\theta \in B, \mathbf{X} \in C) = \int_B \left(\int_C r(\mathbf{x}|\theta) d\nu_n(\mathbf{x}) \right) q(\theta) d\lambda(\theta)$$

pro B, C lib. měř. množiny

Bayesova věta pro podmíněnou hustotu $\pi(\theta|\mathbf{x})$ náhodného vektoru θ při daném \mathbf{x} platí

$$\begin{aligned} \pi(\theta|\mathbf{x}) &= \frac{q(\theta)r(\mathbf{x}|\theta)}{\int_{\Theta} q(\theta)r(\mathbf{x}|\theta)d\lambda(\theta)}, \quad \int_{\Theta} q(\theta)r(\mathbf{x}|\theta)d\lambda(\theta) > 0 \\ &= 0, \quad \text{jinak} \end{aligned}$$

$\pi(\theta|\mathbf{x}) \propto q(\theta)r(\mathbf{x}|\theta)$ – zkrácené značení

$r(\mathbf{x}) = \int_{\Theta} q(\theta)r(\mathbf{x}|\theta)d\lambda(\theta)$ – marginální hustota \mathbf{X}

Odhady, testy i konfindenční množiny se konstruují na základě aposterioního rozdělení, např. maximální aposteriorní věrohodnost

Konjugované systémy rozdělení

Konstrukci vyložíme pro případ: (X_1, \dots, X_n) má hustotu $\prod_{i=1}^n r(x_i|\theta)$ vzhledem k σ -konečné míře $\prod_{i=1}^n \nu(x_i)$, $\theta \in \Theta \neq \emptyset$, $\Theta \in \mathcal{B}_k$, (ν je typicky Lebesgueova míra nebo čítací míra.)

Systém Q apriorních hustot $q(\theta)$ nazveme systémem konjugovaným s hustotami $\{r(x|\theta), \theta \in \Theta\}$, jestliže pro vš. dost velká n a při libovolných hodnotách $\mathbf{X} = \mathbf{x}$, které splňují

$$0 < \int_{\Theta} \prod_{i=1}^n r(x_i|\theta) q(\theta) d\lambda(\theta) < \infty$$

patří aposteriorní hustota do systému Q .

Jsou-li X_1, \dots, X_n i.i.d. s rozdělení $N(\mu, \sigma_0^2)$, $\sigma_0^2 > 0$ známá, konjugované rozdělení parametru μ je normální a $N(a, b^2)$, $a \in \mathcal{R}$, pak aposteriorní rozdělení je

$$N\left(\frac{1}{n} \sum_i X_i \frac{b^2}{b^2 + \sigma_0^2/n} + a \frac{\sigma_0^2/n}{b^2 + \sigma_0^2/n}, \frac{b^2 \sigma_0^2/n}{b^2 + \sigma_0^2/n}\right).$$

2. Bernstein-von-Mises – limitní věty

poprve J. Doob (1949) pro spec. případ, zobežneno mnoha autory

Motivační příklad

X_1, \dots, X_n – i.i.d. (podmíněně), $N(\theta, \sigma_0^2)$, $\sigma_0^2 > 0$ známé
 θ má $N(a, b^2)$, $a \in \mathcal{R}^1$, $b^2 > 0$ -hyperparametry

aposteriorní rozdělení veličiny $\sqrt{n}(\theta - \bar{X}_n)$ je normální

$$N\left(\frac{\sigma_0^2/n}{\sigma_0^2/n+b^2} \sqrt{n}(a - \bar{X}_n), \frac{\sigma_0^2 b^2}{\sigma_0^2/n+b^2}\right)$$

Je-li θ_0 skutečná hodnota parametru θ , pak pro $n \rightarrow \infty$

$$\bar{X}_n \rightarrow \theta_0, \text{ a.s. } \frac{\sigma_0^2 b^2}{\sigma_0^2/n + b^2} \rightarrow \sigma_0^2$$

a také platí pro $n \rightarrow \infty$

$$\sup_x |P\left(\sqrt{n}(\theta - \bar{X}_n)/\sigma_0 \leq x | \mathbf{X}_n\right) - \Phi(x)| \rightarrow 0, \text{ a.s.,}$$

$\Phi(x)$ – distribuční funkce $N(0, 1)$

Poznámka Limitní rozdělení nezávisí na hyperparametrech a, b^2 .

Příklad 1.-připomenutí 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

V knize J.Anděl: *Matematická statistika*, vydaná 1985 nakladatelstvím SNTL, kapitola XVI, je možné nalézt tvrzení i s důkazem ve formě ε, δ .

Zobecnění

X_1, \dots, X_n jsou nezávislé stejně rozdělené s hustotou $r(x|\theta)$ hl.k μ , $\theta \in \Theta$ je parametr $q(\theta)$ – apriorní hustota

Předpokládejme:

(a) Θ je otevřená podmnožina \mathcal{R} ,

(b) $\int \frac{\partial}{\partial \theta} r(x|\theta) d\mu(x) = 0$, $\forall \theta \in \Theta$, a jakási hladkost parciální derivace $r(x|\theta)$ vzhl. k θ integrálu

(c) Fisherova informace $0 < J(\theta) < \infty$

(d) je-li skutečná hodnota parametru θ_0 , pak $q(\theta_0) > 0$ a $q(\theta)$ je spojitá v $(\theta_0 - \epsilon, \theta_0 + \epsilon)$ pro nějaké $\epsilon > 0$.

Je-li $\hat{\theta}$ striktně konsistentní max. věrohodnostní odhad parametru θ , pak pro $n \rightarrow \infty$

$$P(\sqrt{J(\theta_0)n}(\theta - \hat{\theta}) \leq x | \mathbf{X}) \rightarrow^{a.s.} \Phi(x)$$

pro vš. x , kde θ_0 je skutečná hodnota parametru θ

Tato věta se často nazývá "asymptotic normality of the posterior"

Je-li $J(\theta)$ v okolí bodu θ_0 tvrzení platí nahradíme-li $J(\theta_0)$ veličinou $J(\hat{\theta})$.

Existuje mnoho různých zobecnění

Mírné zpřesnění tvrzení jen pro spec. případ

X_1, \dots, X_n jsou nezávislé stejně rozdělené s rozdělením $N(\theta, 1)$, θ - parametr
 $q(\theta)$ - apriorní hustota — dostatečně hladká

Pak platí:

$$P(\sqrt{n}(\theta - \bar{X}_n) \leq x | \mathbf{X}) = \Phi(x) - \frac{q'(\bar{X}_n) \phi(x)}{q(\bar{X}_n) \sqrt{n}} - \frac{q''(\bar{X}_n) x \phi(x)}{q(\bar{X}_n) n} + O(n^{-3/2})$$

stejněměrně v x , $q'(\cdot)$, $q''(\cdot)$ jsou derivace, $\phi(x)$ je hustota $N(0, 1)$

Za určitých podmínek platí: pro θ_0 -skut.hodnota par., $\hat{\theta}$ - max. verhod.odhad

$$E(\theta | \mathbf{X}) = \hat{\theta} + \frac{1}{n} \frac{1}{\sigma(\bar{X}_n)} \left(\frac{q'(\bar{X}_n)}{q(\bar{X}_n)} + a_n(\bar{X}_n) \right) + o_P(n^{-2})$$

$\sigma(\bar{X}_n)$ a $a(\bar{X}_n)$ jsou funkce nezávislejší na $q(\cdot)$.

Ještě pár poznámek – Za určitých podmínek (dost komplikovaných) platí:

θ_0 -skut. hodnota parametru

$\hat{\theta}$ – max. věrohodný odhad (klasický)

$\hat{\theta}^*$ – medián par. θ aposteriorního rozdělení $\pi(\theta|\mathbf{X})$

$$(i) \sqrt{n}(\hat{\theta}^* - \hat{\theta}) \xrightarrow{P_{\theta_0}} 0, \quad \forall \theta,$$

$$\sqrt{n}(\hat{\theta}^* - \theta) \xrightarrow{\mathcal{D}} N(0, J^{-1}(\theta)),$$

$$(ii) E \left[\sqrt{n}(|\hat{\theta} - \theta| - |\hat{\theta}^* - \hat{\theta}|) | \mathbf{X} \right] = o(1)$$

$$E \left[\sqrt{n}(|\theta - \hat{\theta}| - |\theta|) | \mathbf{X} \right] = \min_d E \left[\sqrt{n}(|\theta - \hat{\theta}| - |d - \theta|) | \mathbf{X} \right] + o_P(1)$$

(i) pro nebayesovský přístup (ii) pro bayesovský přístup

Výše uvedené výsledky byly zobecněny na většinu "rozumných" parametrických konečně-dimenzionálních modelů. Pro případ dimenze pozorování rostoucích zároveň s počtem pozorování a u neparametrických modelů je situace jiná. Tím se nebudeme zabývat.

Tato část přednášky byla připravena na základě kapitoly 20 v knize

A. Das Gupta: *Asymptotic Theory of Statistics and Probability*, Springer 2008.

2. Steinův efekt; James-Steinův odhad

$\mathbf{X} \sim N_p(\theta, I_p)$, I_p – jednotková matice $p \times p$

úloha: odhad parametru θ

$\hat{\theta} = \mathbf{X}$ – LSE, NNLO, max. věrohodný odhad

$L(\theta, \delta(\mathbf{X})) = \|\theta - \delta(\mathbf{X})\|^2$ – kvadratická ztrátová funkce

$$EL(\theta, \hat{\theta}(\mathbf{X})) = p, \quad E\mathbf{X} = \theta$$

Pro $p > 2$ existuje odhad $\delta^{JS}(\mathbf{X})$ s vlastností

$$E(L(\theta, \delta^{JS}(\mathbf{X}))|\theta) < E(L(\theta, \hat{\theta}(\mathbf{X}))|\theta)$$

James a Stein (1961) navrhli:

$$\delta^{JS}(\mathbf{X}) = \left(1 - \frac{p-2}{\|\mathbf{X}\|^2}\right)\mathbf{X},$$

$$\delta^{JS+}(\mathbf{X}) = \left(1 - \frac{p-2}{\|\mathbf{X}\|^2}\right)_+ \mathbf{X}$$

$$x_+ = \max(x, 0)$$

James-Stein odhad jako empirický bayesovský odhad

$X_i \sim N(\theta_i, 1)$, $i = 1, \dots, p$ nezávislé (podmíněně)

$\theta_i \sim N(0, \tau^2)$, $\tau^2 > 0$ nezávislé

Rozdělení \mathbf{X} při daném $\tau^2 \sim N(p\mathbf{0}, (1 + \tau^2)\mathbf{I})$

τ^2 odhadneme met. max. věrohodnosti, t.j.

$$\max_{\tau^2 > 0} \prod_{i=1}^p \frac{1}{\sqrt{2\pi(1 + \tau^2)}} \exp\left\{-\frac{\sum_i X_i^2}{2(1 + \tau^2)}\right\}$$

dostaneme

$$\begin{aligned} \hat{\tau}^2 &= \frac{1}{p} \sum_{i=1}^p X_i^2 - 1, & \sum_{i=1}^p X_i^2 > p, \\ &= 0, & \text{jinak} \end{aligned}$$

aposteriorní rozdělení $\pi(\boldsymbol{\theta}|\mathbf{X})$ je $N_p(\mathbf{X} \frac{\tau^2}{1+\tau^2}, \frac{\tau^2+1}{\tau^2})$

Tedy

$$\delta_B(\mathbf{X}) = \mathbf{X} \frac{\tau^2}{1 + \tau^2}$$

a po nahrazení $\hat{\tau}^2$ za τ^2 dostaneme

$$\hat{\delta}_B(\mathbf{X}) = \mathbf{X} \left(1 - \frac{p}{\sum_i X_i^2}\right)_+$$