

## Bayesovské metody,2

28. září 2020

# Outline

Bayesovské  
metody,  
2

## Outline

Opakování  
z před-  
chozího

Apriorní  
rozdělení

- 1 Opakování z předchozího

# Outline

## Outline

Opakování  
z před-  
chozího

Apriorní  
rozdělení

1 Opakování z předchozího

2 Apriorní rozdělení

# Outline

1 Opakování z předchozího

2 Apriorní rozdělení

**Obecná Bayesova věta**

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

$\mathbf{X} = (X_1, \dots, X_n)^\top$  – náhodný vektor s podmíněnou hustotou  $r(\mathbf{x}|\theta)$  při daném  $\theta$  vzhl. k  $\sigma$  -konečné míře  $\nu_n$  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  $\theta$  při daném  $\mathbf{x}$  platí

$$\pi(\theta|\mathbf{x}) = \frac{q(\theta)r(\mathbf{x}|\theta)}{\int_{\Theta} q(\theta)r(\mathbf{x}|\theta)d\lambda(\theta)}, \quad \int_{\Theta} q(\theta)r(\mathbf{x}|\theta)d\lambda(\theta) > 0$$

$$= 0, \quad \text{jinak}$$

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

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

$q(\theta)$  – apriorní hustota

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

# Outline

Bayesovské  
metody,  
2

Outline

Opakování  
z před-  
chozího

**Apriorní  
rozdělení**

1 Opakování z předchozího

2 **Apriorní rozdělení**

## Základní problémy

- Volba apriorního rozdělení
- konstrukce odhadů, testů, konfidenčních množin (založeny na aposteriorních rozděleních)

## Volby apriorního rozdělení

Velice důležité a často obtížné

- známe, vyplyne z kontextu, popř. známe z minulosti z obdobných situací-viz příklad s IQ dítěte
  - **konjugované rozdělení** – volíme, tak aby apriorní i aposteriorní rozdělení bylo téhož typu – nejpoužívanější
  - princip nečitosti – stejná váha všem možným hodnotám parametrů, Jeffreysova věta
  - empirické bayesovské metody – využijí se pozorování získaných za obdobné situace v minulosti
  - často se volí tak, aby odhady nebayesovské i bayesovské byly stejné
  - Existují i další metody, některé později
- 

- Odhady, testy i konfidenční množiny se konstruují na základě aposteriorního 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  $\sigma$ -konečné míře  $\prod_{i=1}^n \nu(x_i)$ ,  $\theta \in \Theta \neq \emptyset$ ,  $\Theta \in \mathcal{B}_k$ , ( $\nu$  je typicky Lebesgueova míra nebo čítecí 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  $Q$ .

Systémů typicky existuje mnoho, ale je vhodné nalézt menší systémy.

Jedna možná konstrukce založená na postačujících statistikách. Tu si uvedeme.



Předpokládejme, že existuje  $n_0$  takové, že pro vš.  $n_0 \leq n$  existují nezáporné funkce  $g_n$  a  $h_n$  takové, že:

$$\prod_{i=1}^n r(x_i | \theta) = g_n(\mathbf{T}_n(\mathbf{x}); \theta) h_n(\mathbf{x})$$

že  $\mathbf{T}_n$  je  $r$ -rozměrná postačující statistika,  $r$  nezávisí na  $n$

Ozn.  $S_n = \{\mathbf{t}; \mathbf{t} = \mathbf{T}_n(\mathbf{X}), 0 < \int_{\Theta} g_n(\mathbf{t}; \theta) d\lambda(\theta) < \infty\}$

Definujme

$$f_{n,\mathbf{t}}(\theta) = g_n(\mathbf{t}; \theta) \left( \int_{\Theta} g_n(\mathbf{t}; \theta) d\lambda(\theta) \right)^{-1}$$

Systém hustot  $\{f_{n,\mathbf{t}}(\theta), \mathbf{t} \in S_n, n \geq n_0\}$  je konjugovaný se systémem  $\{r(x|\theta), \theta \in \Theta\}$ .

Náznak odvození: Stačí ukázat, že pro aposteriorní rozdělení  $\pi(\theta|\mathbf{X})$  příslušné apriornímu rozdělení  $f_{m,\mathbf{t}}(\theta)$ ,  $\mathbf{t} \in S_m$ ,  $m \geq n_0$ , platí

$$\pi(\theta|\mathbf{x}) \propto f_{m,\mathbf{t}}(\theta) \prod_{i=1}^n r(x_i | \theta) \propto g_m(\mathbf{t}; \theta) g_n(\mathbf{T}_n(\mathbf{x}); \theta)$$

Stačí si uvědomit, že existují náhodné veličiny  $Y_1, \dots, Y_m$ , že  $(X_1, \dots, X_n, Y_1, \dots, Y_m)$ , podmíněnou hustotu

$$\prod_{i=1}^n r(x_i | \theta) \prod_{j=1}^m r(y_j | \theta) \propto g_m(\mathbf{T}_m(\mathbf{y}); \theta) g_n(\mathbf{T}_n(\mathbf{x}); \theta)$$

## Příklady některých systémů konjugovaných rozdělení

Předpokládáme –  $X_1, \dots, X_n$  – iid ,  $X_i$

- má-li  $X_i$ , binomické rozdělení s parametry  $m, p$ ,  $p \in (0, 1)$  je parametr zájmu, pak platí

$$r(x|p) = P(X_i = x|p) = \binom{m}{x} p^x (1-p)^{m-x}, \quad x = 0, \dots, m$$

konjugované rozdělení parametru  $p$  je beta rozdělení

$$q(\theta) \propto p^{\alpha-1} (1-p)^{\beta-1}, \quad p \in (0, 1), \quad \alpha > 0, \beta > 0$$

Je-li apriorní rozdělení  $\text{beta}(\alpha, \beta)$  pak aposteriorní rozdělení je  $\text{beta}(\alpha + \sum_i X_i, \beta + mn - \sum_i X_i)$

- má-li  $X_i$ , Poissonovo rozdělení s parametrem  $\lambda > 0$ , platí

$$r(x|p) = P(X_i = x|p) = \exp\{-\lambda\} \frac{\lambda^x}{x!}, \quad x = 0, \dots,$$

konjugované rozdělení parametru  $\lambda$  je rozdělení

$$q(\lambda) \propto \lambda^{\alpha-1} \exp\{-\lambda\beta\}, \quad \lambda > 0, \quad \alpha > 0, \beta > 0$$

Je-li apriorní rozdělení  $\text{gamma}(\alpha, \beta)$  pak aposteriorní rozdělení je  $\text{gamma}(\alpha + \sum_i X_i, \beta + n)$

- má-li  $X_i$  rozdělení  $N(\mu, \sigma_0^2)$ , variance  $\sigma_0^2$  známá,  $\mu$  je parametr zájmu, hustota  $(X_1, \dots, X_n)$  má tvar

$$r(\mathbf{x}|\mu) = \left(\frac{1}{2\pi\sigma_0^2}\right)^{n/2} \exp\left\{-\frac{\sum_i (x_i - \mu)^2}{\sigma_0^2}\right\}$$

konjugované rozdělení parametru  $\mu$  je  $N(a, b^2)$ ,  $a \in \mathcal{R}$ ,  $b^2 > 0$

Je-li apriorní rozdělení  $N(a, b^2)$ , pak aposteriorní rozdělení je

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

- má-li  $X_i$  rozdělení  $N(\mu_0, \sigma^2)$ ,  $\mu_0$  známá, konjugované rozdělení parametru  $\sigma^{-2}$  je gama rozdělení  $t, m/2$ ,  $t > 0$ ,  $m = 1, 2, \dots$

Je-li apriorní rozdělení gama  $t, m/2$ ,  $t > 0$ ,  $m = 1, 2, \dots$  pak aposteriorní rozdělení je gama  $t + \sum_i (X_i - \mu_0)^2/2$ ,  $(m + n)/2$

- má-li  $X_i$  rozdělení  $N(\mu, \sigma^2)$ , konjugované rozdělení pro  $\mu$ ,  $\sigma^{-2}$  je normální-gama rozdělení:  $\mu$  podmíněno  $\sigma^{-2}$  je  $N(a, \sigma^2/r)$ ,  $\sigma^{-2}$  má gama rozdělení  $(c, d)$ , tedy parametry tohoto rozdělení jsou  $(a, r, c, d)$ ,  $a \in \mathcal{R}_1$ ,  $r > 0$ ,  $2d = 1, 2, \dots$ ,  $d > 0$

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

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

Otázka je apriorní a aposteriorní rozdělení  $\mu$  – lze spočítat jako marginální rozdělení

Ve skritech jsou další příklady rozdělení – exponenciální, rovnoměrné a různá mnohorozměrná.

Výše uvedená metoda dává jen systém apriorních rozdělení, která závisí na parametru – **hyperparametry**. Toto je problém a řeší se různě.

## Princip neurčitosti

- apriorní rozdělení rovnoměrné na množině možných hodnot parametru, jen u rozptylu se obvykle volí jinak,

$$q_0(\theta) = 1, \quad \theta \in \Theta$$

Někdy  $\int_{\Theta} q_0(\theta) d\lambda(\theta) = \infty$  pak mluvíme o **nevlastní hustotě** – lze použít opatrně

Má řadu nevýhod, nejpodstatnější souvisí se změnou parametrizace.

Např. jsou-li  $X_1, \dots, X_n$  i.i.d. s Poissonovým, rozdělením s parametrem  $\theta > 0$  a volíme apriorní rozdělení  $q_0(\theta) = 1$  pro  $\theta > 0$ , jinak 0, pak aposteriorní je gama s parametry  $(n, \sum_i X_i + 1)$ .

Při parametrizaci  $\lambda = \sqrt{\theta}$ , toto apriorní rozdělení odpovídá  $q(\lambda) = \lambda$ ,  $\lambda > 0$ . Tedy není již rovnoměrné.

## Jeffreysova hustota

Jeffreys navrhl apriorní hustotu, která která "nezávisí na parametrizaci".

Regulární systém hustot tvaru  $\{r(\mathbf{x}|\theta); \theta \in \Theta\}$  splňuje:

- $\Theta$  neprázdná otevřená množina v  $\mathcal{R}_k$ .
- $M = \{\mathbf{x}; r(\mathbf{x}|\theta) > 0\}$  nezávisí na  $\theta$ .
- Pro skoro vš.  $\mathbf{x} \in M$  (vzhledem k  $\sigma$ - konečné míře  $\nu_n$ ) existuje konečná parciální derivace  $r'_i(\mathbf{x}|\theta) = \frac{\partial r(\mathbf{x}|\theta)}{\partial \theta_i}$ ,  $i = 1, \dots, k$ .
- Pro každé  $i$  a pro vš.  $\theta \in \Theta$  platí  $\int_M r'_i(\mathbf{x}|\theta) d\nu_n(\mathbf{x}) = 0$ .
- Pro každou dvojici  $(i, j)$  existuje konečný integrál

$$J_{i,j}(\theta) = \int_M \frac{r'_i(\mathbf{x}|\theta)r'_j(\mathbf{x}|\theta)}{r^2(\mathbf{x}|\theta)} r(\mathbf{x}|\theta) d\nu_n(\mathbf{x})$$

- Matice  $\mathbf{J}(\theta) = (J_{i,j}(\theta))_{i,j=1,\dots,k}$  je pozitivně definitní pro každé  $\theta$ . Fisherova informační matice.

**Jeffreysova věta**  $\mathbf{X} = (X_1, \dots, X_n)^\top$  s podmíněnou hustotou  $r(\mathbf{x}|\theta)$  splňující podmínky regularity. Předpokládejme

$$c = \int_{\Theta} r(\mathbf{x}|\theta) (\det \mathbf{J}(\theta))^{1/2} d\theta \in (0, \infty)$$

$H$  – regulární prosté zobrazení  $\Theta$  na  $\Theta^* \in \mathcal{B}_k$ . Ozn.  $\boldsymbol{\eta} = H(\theta)$ ,  $r^*(\mathbf{x}|\boldsymbol{\eta}) = r(\mathbf{x}|H^{-1}\boldsymbol{\eta})$ . Pak  $\{r^*(\mathbf{x}|\boldsymbol{\eta}), \boldsymbol{\eta} \in \Theta^*\}$  je regulární systém a platí pro lib.  $B \in \mathcal{B}_k$

$$\int_B c^{-1} r(\mathbf{x}|\theta) (\det \mathbf{J}(\theta))^{1/2} d\theta = \int_{H(B)} c^{-1} r^*(\mathbf{x}|\boldsymbol{\eta}) (\det \mathbf{J}^*(\boldsymbol{\eta}))^{1/2} d\boldsymbol{\eta}$$

kde  $\mathbf{J}^*(\boldsymbol{\eta})$  je Fisherova inf. matice a  $\mathbf{D} = \left( \frac{\partial \eta_u}{\partial \theta_i} \right)_{i,u=1,\dots,k}$

Platí  $\mathbf{J}(\theta) = \mathbf{D}^\top \mathbf{J}^*(\boldsymbol{\eta}) \mathbf{D}$ .

Tvrzení věty říká:  $P(\boldsymbol{\theta} \in B|\mathbf{x}) = P(\boldsymbol{\eta} \in H(B)|\mathbf{x})$

Volba apriorního rozdělení - Jeffreysova hustota:  $q(\boldsymbol{\theta}) = (\det \mathbf{J}(\boldsymbol{\theta}))^{1/2}$

Tady je výsledek pro některá rozdělení:

pro binomické rozdělení s parametry  $(m, p)$ , apriorní rozd. je beta  $(1/2, 1/2)$

pro Poissonovo rozdělení s  $\theta$  apriorní rozd. je gama  $(0, 1/2)$

## Empirické bayesovské metody

Jsou k dispozici obdobná data z minulosti –  $Y_1, \dots, Y_N$ , podmíněně nezávislé,  $Y_i$  s hustotou  $r(y|\theta_i)$ ,  $i = 1, \dots, N$ ,  $\theta_1, \dots, \theta_N$  jsou nezávislé stejně rozdělené s hustotou  $q(\theta)$

Pak nepodmíněně rozdělení  $Y_i$  je  $r_q(y) = \int_{\Theta} r(y|\theta)q(\theta)d\lambda(\theta)$ , kde  $q(\theta) \in \{q(\theta; \alpha), \alpha \in \Upsilon\}$  –  $\alpha$  – parametr

Tedy  $Y_1, \dots, Y_n$  jsou nezávislé stejně rozdělené s hustotou závisující na  $\alpha$ .

$\alpha$  na základě  $Y_1, \dots, Y_n$  odhadneme některou klasickou metodou, ozn.  $\hat{\alpha}$  a pak použijeme jako apriorní rozdělení  $q(\theta; \hat{\alpha})$ . Často uijeme momentovou metodou.

*Příklad*  $Y_i$  má (podmíněně) rozdělení  $N(\theta, \sigma_0^2)$ ,  $\sigma_0^2$  je známé,  $\theta_i \sim N(\mu_q, \sigma_q^2)$ ,  $\alpha = (\mu_q, \sigma_q^2)$ . Nepodmíněně rozdělení  $Y_i$  je  $N(\mu_q, \sigma^2)$ ,  $\sigma^2 = \sigma_0^2 + \sigma_q^2$   
Použijeme odhady

$$\hat{\mu}_q = \frac{1}{N} \sum_{i=1}^N Y_i, \quad \hat{\sigma}^2 = \frac{1}{N-1} \sum_{i=1}^N (Y_i - \bar{Y}_N)^2, \quad \bar{Y}_N = \frac{1}{N} \sum_{i=1}^N Y_i.$$

Za apriorní rozdělení vezmeme  $N(\hat{\mu}_q, \hat{\sigma}_q^2)$ , kde  $\hat{\sigma}_q^2 = \max(\hat{\sigma}^2 - \sigma_0^2, 0)$



. Existuje řada zobecnění:

*Konvexní směs konjugovaných rozdělení*

*Hierarchický bayesovský model*

$$q(\theta_0) = \int_{\Theta_1 \times \Theta_2} q_1(\theta_0|\theta_1)q_2(\theta_1|\theta_2)q_3(\theta_2)d\theta_1 d\theta_2$$

$q_2(\theta_1|\theta_2)$  – podmíněná hustota  $\theta$  při daném  $\theta_2$

$\theta_1, \theta_2$  - hyperparametry 1. resp.2. úrovně

$\theta = (\theta_0^\top, \theta_1^\top, \theta_2^\top)^\top$  – parametry apriorního rozdělení

Outline

Opakování  
z před-  
chozího

Apriorní  
rozdělení