

Příklad (házení mincí)

20x hodíme mincí. Padlo nám celkem $m_1 = 5$ líc. Jaka je pravděpodobnost, že nám v daném hodě padne líc?

klíčový

X_1, \dots, X_m je náh. vstáv. z $A(\theta)$, $\theta \in (0, 1)$ je hledaná pravděpodobnost

$X_i < \begin{cases} 1 & \dots \text{v } i\text{-tém hodu padne líc} \\ 0 & \dots \text{jináč} \end{cases}$

hodový odhad $\hat{\theta}$:

$$\hat{\theta} = \bar{X} = \frac{m_1}{m} = \frac{5}{20} = 0,25.$$

interval spolehlivosti pro θ je: $\left(\hat{\theta} - \mu_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{m}}, \hat{\theta} + \mu_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{m}} \right) \stackrel{\text{pro } \alpha=0,05}{\downarrow} = (0,06; 0,44)$

predikce budoucího pozorování X_{m+1} : $X_{m+1} \sim A(\hat{\theta})$: $P(X_{m+1}=1 | X_1, \dots, X_m) = \hat{\theta} = 0,25$,
 $P(X_{m+1}=0 | X_1, \dots, X_m) = 1 - \hat{\theta} = 0,75$.

Bayesovský

- potřebujeme apriorní rozdělení parametru θ (nezávislé na našich datech)

• scénář 1: méně křivýj rozdělení, tedy malýjí hodnoty kolem 0,5

$$\theta \sim \text{Beta}(100, 100)$$

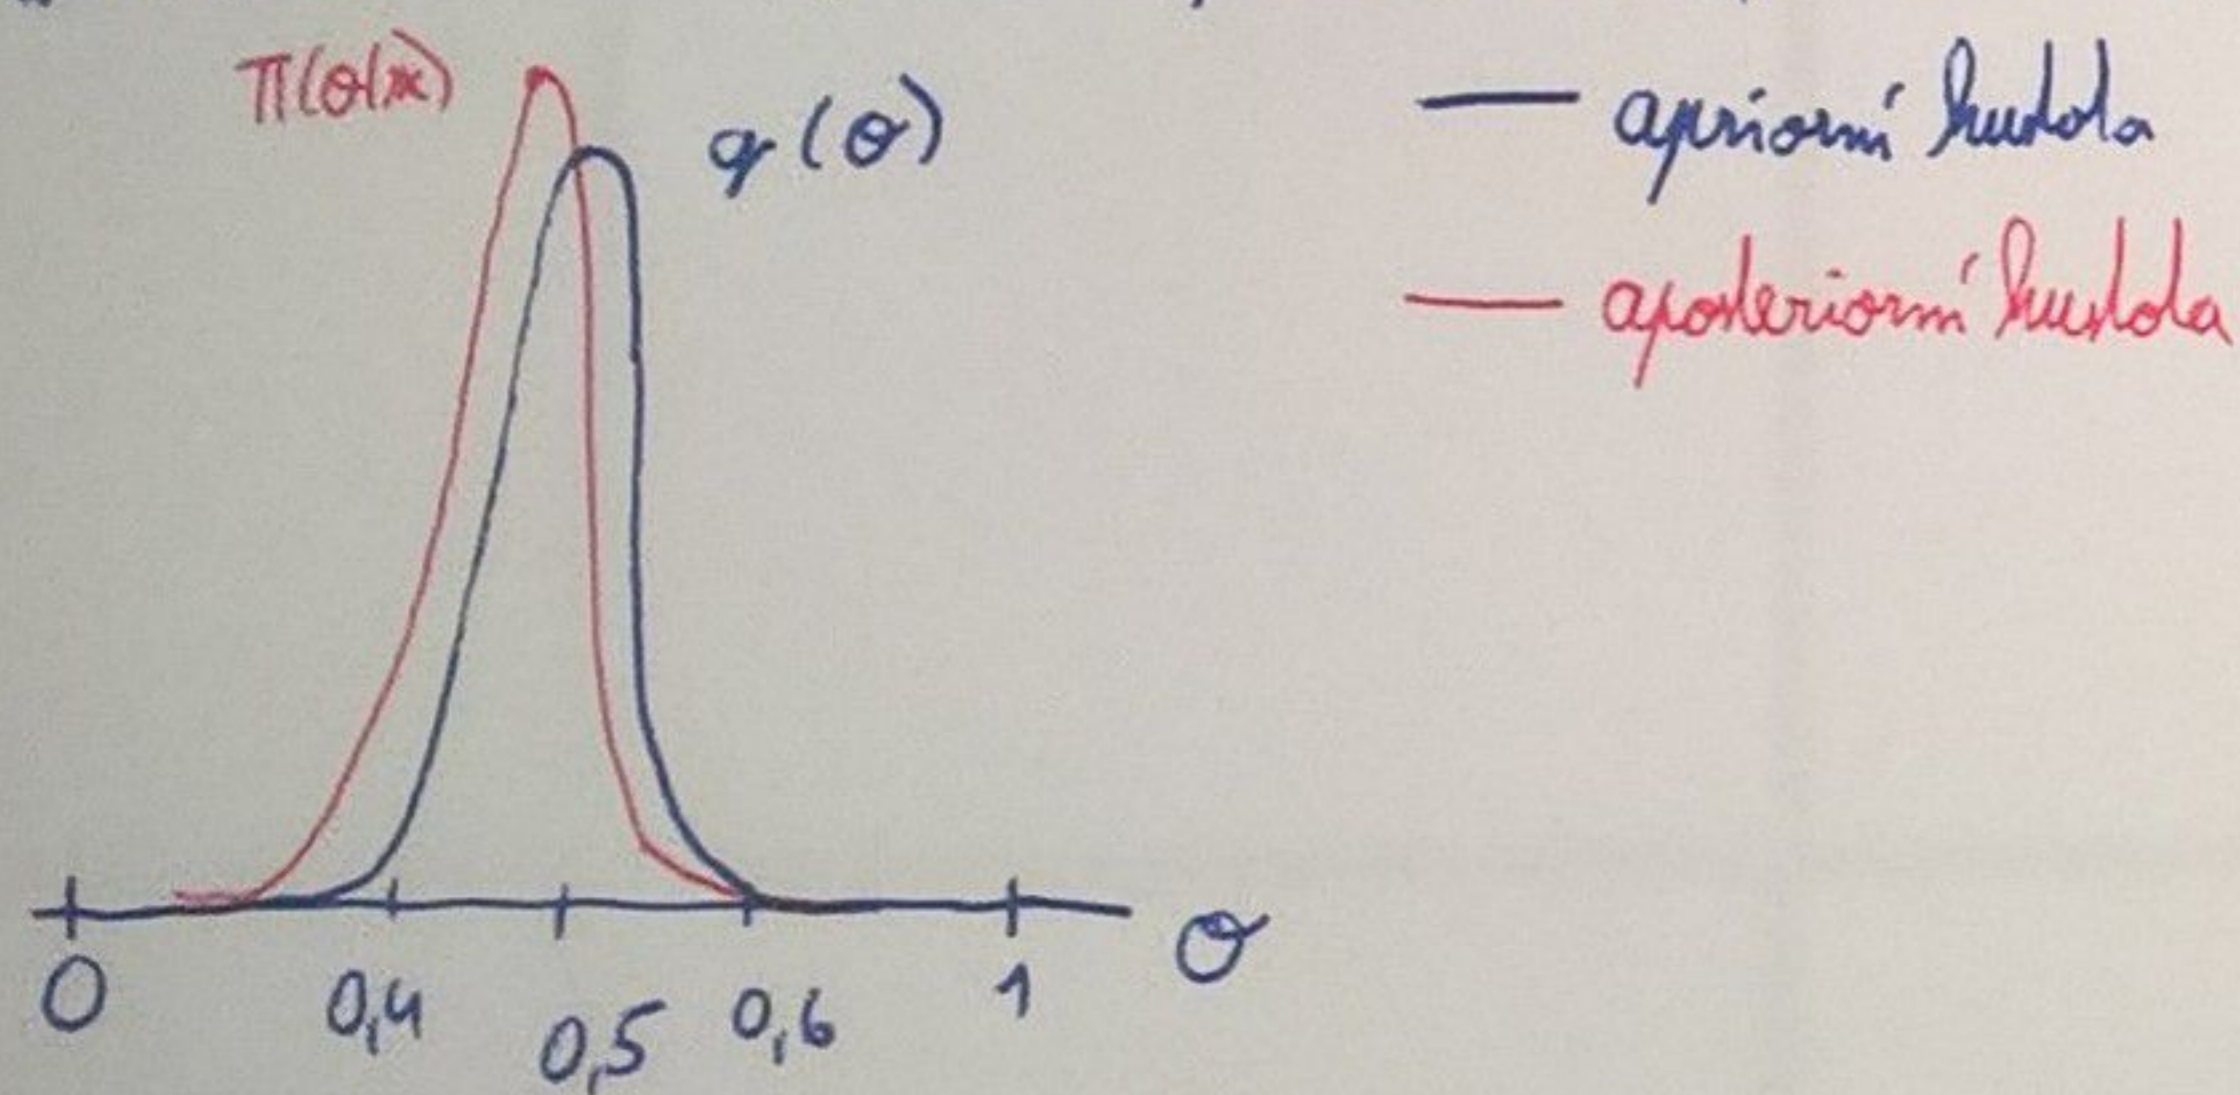
hledá rozdělení $\text{Be}(\alpha, \beta)$ je $g(\theta, \alpha, \beta) = \frac{1}{\text{Be}(\alpha, \beta)} \cdot \theta^{\alpha-1} (1-\theta)^{\beta-1}$, $0 < \theta < 1$, kde $\text{Be}(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}$ je beta funkce.

$$f(x_i, \theta) = \theta^{x_i} \cdot (1-\theta)^{1-x_i}, \quad x_i = 0, 1$$

něrohodnost $\pi(x|\theta) = \pi(x_1, \dots, x_m|\theta) = \prod_{i=1}^m f(x_i, \theta) = \theta^{\sum x_i} \cdot (1-\theta)^{m-\sum x_i} = \theta^{m_1} \cdot (1-\theta)^{m-m_1}$

Bayesova věta: $\pi(\theta|x) \propto \underbrace{\frac{1}{\text{Be}(100, 100)}}_{q(\theta)} \cdot \theta^{99} (1-\theta)^{99} \cdot \underbrace{\theta^{m_1} (1-\theta)^{m-m_1}}_{\pi(x|\theta)} \propto \theta^{99+m_1} \cdot (1-\theta)^{99+m-m_1}$

Tedy $\theta|x \sim \text{Beta}(100+m_1, 100+m-m_1) = \text{Beta}(105, 115)$ aposteriorní rozdělení je také beta rozdělení (je to konjugované rozdělení).



my chceme ale bodový odhad parametru θ .

Bayesova teorie - teorie ztrátových funkcí

$L: \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ je ztrátová funkce, jestliže $L(x, x) = 0$, $L(x, y) \geq 0$, $\forall x, y \in \mathbb{R}$

$L(\theta, \hat{\theta})$... ztráta, kterou utrpíme, $\hat{\theta}$ -li skutečná hodnota parametru rovná θ a my ho odhadujeme pomocí $\hat{\theta}$.

Bayesová věta: $\pi(\hat{\theta}) = \int_{\Theta} L(\theta, \hat{\theta}) \pi(\theta|x) d\theta$... průměrná aposteriorní ztráta \Rightarrow hledáme odhad, který pro danou ztrátovou funkci L minimalizuje Bayesovské riziko

Příklady:

• $L(\theta, \hat{\theta}) = (\theta - \hat{\theta})^2$... kvadratická ztrátová funkce

$$\hat{\theta}_1 = \underset{\theta \in \Theta}{\operatorname{argmin}} \int (\theta - \hat{\theta})^2 \pi(\theta | x) d\theta = E(\theta | X_1, \dots, X_n) \text{ aposteriorní střední hodnota}$$

• $L(\theta, \hat{\theta}) = |\theta - \hat{\theta}|$... absolutní ztrátová funkce

$$\hat{\theta}_2 = \operatorname{median}(\theta | X_1, \dots, X_n) \text{ aposteriorní medián}$$

• $L(\theta, \hat{\theta}) = \mathbb{1}_{\{\theta \neq \hat{\theta}\}}$... zero-one ztrátová funkce

$$\hat{\theta}_3 = \underset{\theta \in \Theta}{\operatorname{argmax}} \pi(\theta | X_1, \dots, X_n) \text{ aposteriorní módus (metoda maximální aposteriorní věrohodnosti)}$$

Intervalový odhad θ

Klasický: θ je neznámý : $P(L(X_1, \dots, X_n) \leq \theta \leq H(X_1, \dots, X_n)) = 1 - \alpha$, $\forall \theta \in [L, H]$ je $(1 - \alpha) \cdot 100\%$ interval spolehlivosti pro θ

Bayesovský: θ je náh. veličina \Rightarrow má smysl počítat pravděpodobnost, že parametr θ náleží danému intervalu (věrohodnostní interval, credibility interval)

$[a, b] = [a(X_1, \dots, X_n), b(X_1, \dots, X_n)]$ je $(1 - \alpha) \cdot 100\%$ věrohodnostní interval pro parametr θ , jestliže $P(a(x) \leq \theta \leq b(x) | X) = 1 - \alpha$.

• $100(1 - \alpha)\%$ symetrický věrohodnostní interval (equal tail) je interval $[a, b]$, kde $a = \frac{\alpha}{2}$ - kvantil aposteriorního rozdělení $\theta | X$
 $b = 1 - \frac{\alpha}{2}$ - kvantil -||-

• $100(1 - \alpha)\%$ věrohodnostní interval s nejvyšší aposteriorní hustotou (HPD) je interval $[a, b]$ takový, že $\pi(\theta | x) \geq c$, $\forall \theta \in [a, b]$ a c je největší číslo takové, že

$$P(\pi(\theta | x) \geq c) = 1 - \alpha.$$

Trava

θ -li $\pi(\theta|x)$ spája a unimodálnu, paž HPD interval je najkratší medzi všetmi $100 \cdot (1-\alpha)\%$ verodostupnými intervaly.

Predikcia budúceho pozorovania

Keďže odhadneme hodnotu májajúcu máj. veličiny X_{m+1} splývajúci s tým model jako prirodni data X_1, \dots, X_m .

Tedy X_{m+1} má hustotu $f(X_{m+1}, \theta)$

aposteriori predikčiomá hustota $f(X_{m+1}|x) = \int f(X_{m+1}, \theta) \cdot \pi(\theta|x) d\theta$.
(H)

Príklad - počítačovanie

$X \sim \text{Beta}(\alpha, \beta) \Rightarrow EX = \frac{\alpha}{\alpha+\beta}$, modus $X = \frac{\alpha-1}{\alpha+\beta-2}$, median $X = \frac{\alpha-\frac{1}{3}}{\alpha+\beta-\frac{2}{3}}$

10 májím prípad: aposteriori rozdelenie $\theta|x \sim \text{Beta}(105, 115)$

$\hat{\theta}_1 = E(\theta|x) = \frac{105}{220} = 0,477$

95% equal tail ver. interval je $[0,412; 0,543]$,
95% HPD ver. interval je $[0,419; 0,535]$.

$\hat{\theta}_2 = \text{median}(\theta|x) = 0,477$

$\hat{\theta}_3 = \text{modus}(\theta|x) = 0,477$

predikcia budúceho pozorovania $X_{m+1} : f(X_{m+1}, \theta) = \theta^{X_{m+1}} \cdot (1-\theta)^{1-X_{m+1}}$, pro $X_{m+1} = 0, 1$.

$f(X_{m+1}|x) = \int_0^1 \theta^{X_{m+1}} \cdot (1-\theta)^{1-X_{m+1}} \cdot \frac{\theta^{104} \cdot (1-\theta)^{114}}{\text{Be}(105, 115)} d\theta = \frac{1}{\text{Be}(105, 115)} \cdot \int_0^1 \theta^{104+X_{m+1}} \cdot (1-\theta)^{115-X_{m+1}} d\theta = \frac{\text{Be}(105+X_{m+1}, 116-X_{m+1})}{\text{Be}(105, 115)}$, $X_{m+1} = 0, 1$.

$$f(0|x) = P(X_{m+1} = 0|x) = 0,522$$

$$f(1|x) = P(X_{m+1} = 1|x) = 0,478$$

scénář 2: žádná apriorní informace o parametru θ

$$g(\theta) = 1, \quad 0 < \theta < 1 \dots \theta \sim R_s(0,1) = \text{Beta}(1,1)$$

scénář 3: Jeffreysova apriorní hustota

$$J(\theta) = \frac{1}{\theta(1-\theta)} \quad \text{je Fisherova informace příslušná } X_i$$

$$g(\theta) \propto \sqrt{|J(\theta)|} = \theta^{-\frac{1}{2}} \cdot (1-\theta)^{-\frac{1}{2}}, \quad 0 < \theta < 1 \dots \theta \sim \text{Beta}\left(\frac{1}{2}, \frac{1}{2}\right)$$

Matematické poznámky

$$\text{Bayesova věta: } \pi(\theta|x) = \frac{\pi(x|\theta) \cdot g(\theta)}{\int \pi(x|\theta) \cdot g(\theta) d\theta}$$

výpočet tohoto integrálu může být náročný

• numerická integrace

• simulace pomocí Monte Carlo metody

Příklad

vypočet integrálu $\int_0^1 x^9 dx = \frac{1}{10}$

X_1, \dots, X_m je máh. vztl. z $Rs(0,1)$, definujme $I_m = \frac{1}{m} \sum_{i=1}^m X_i^9 \xrightarrow[m \rightarrow \infty]{\text{d.j.}} \int_0^1 x^9 dx = \frac{1}{10}$. Proč to funguje?

Silný zákon velkých čísel: X_1, \dots, X_m je máh. vztl., pak $\frac{1}{m} \sum_{i=1}^m h(X_i) \xrightarrow[m \rightarrow \infty]{\text{d.j.}} E h(X_1)$.

Použití:

• Necht $\Theta_1, \dots, \Theta_m$ je máh. vztl. z apriorního rozdělení \triangleright hustotou $g(\Theta)$.

• Integrál $I = \int_{\Theta} \pi(x|\Theta) \cdot g(\Theta) d\Theta$ aproximujme pomocí $I_m = \frac{1}{m} \sum_{i=1}^m \pi(x|\Theta_i)$ (SZVĚ: $I_m \xrightarrow[m \rightarrow \infty]{\text{d.j.}} I$).

Vypočet aposteriorní střední hodnoty $E(\Theta|x) = \int_{\Theta} \Theta \cdot \pi(\Theta|x) d\Theta = \int_{\Theta} \Theta \frac{\pi(x|\Theta) \cdot g(\Theta)}{\int_{\Theta} \pi(x|\Theta) \cdot g(\Theta) d\Theta} d\Theta = \frac{\int_{\Theta} \Theta \cdot \pi(x|\Theta) \cdot g(\Theta) d\Theta}{\int_{\Theta} \pi(x|\Theta) \cdot g(\Theta) d\Theta}$

Integrál J aproximujme pomocí $J_m = \frac{1}{m} \sum_{i=1}^m \Theta_i \cdot \pi(x|\Theta_i)$.