

# Bayesovské metody

Jan Kracík

jan.kratic@vsb.cz

## Rozhodování za neurčitosti:

- rozhodování: volíme jednu z alespoň dvou možností
- neurčitost: nelze přesně určit důsledky rozhodnutí
- rozhodování sleduje zadané cíle
- snaha minimalizovat neurčitost

## Rozhodování za neurčitosti:

- rozhodování: volíme jednu z alespoň dvou možností
- neurčitost: nelze přesně určit důsledky rozhodnutí
- rozhodování sleduje zadané cíle
- snaha minimalizovat neurčitost

## Reprezentace neurčitosti:

- pravděpodobnost
- fuzzy modely
- nepřesné pravděpodobnosti

## Bayesovská teorie

- normativní teorie rozhodování za neurčitosti
- axiomatické základy
- racionální v jasně definovaném smyslu

## Bayesovská teorie

- normativní teorie rozhodování za neurčitosti
- axiomatické základy
- racionální v jasně definovaném smyslu

## Základní principy:

- neznámé veličiny považovány za náhodné
- neurčitost reprezentována pomocí pravděpodobnosti
- cíle popsány ztrátovou funkcí
- minimalizace střední hodnoty ztrátové funkce

Výchozí myšlenka: **NEZNÁMÉ = NÁHODNÉ**

Výchozí myšlenka: **NEZNÁMÉ = NÁHODNÉ**

Počátky:

- Thomas Bayes
- Pierre-Simon Laplace
- konec 18. století

Výchozí myšlenka: **NEZNÁMÉ = NÁHODNÉ**

Počátky:

- Thomas Bayes
- Pierre-Simon Laplace
- konec 18. století

Příklad: hod mincí

- deterministický proces
- neznáme poč. podmínky, parametry, neumíme dost přesně počítat
- dokonalý náhodný pokus
- náhoda v běžném smyslu je důsledek nedostatku znalostí, schopností



# Základní pojmy a vztahy z teorie pravděpodobnosti

Bayesovská statistika se opírá o několik základních vztahů z teorie pravděpodobnosti.

Náhodné jevy  $A, B, C$ ;  $P(A) > 0, P(B) > 0, P(C) > 0$ .

- Podmíněná pravděpodobnost:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

Odtud plyne

$$P(A \cap B) = P(A|B)P(B).$$

# Základní pojmy a vztahy z teorie pravděpodobnosti

Bayesovská statistika se opírá o několik základních vztahů z teorie pravděpodobnosti.

Náhodné jevy  $A, B, C$ ;  $P(A) > 0, P(B) > 0, P(C) > 0$ .

- Podmíněná pravděpodobnost:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

Odtud plyne

$$P(A \cap B) = P(A|B)P(B).$$

- Řetězové pravidlo:

$$P(A \cap B \cap C) = P(A|B \cap C)P(B|C)P(C)$$

# Základní pojmy a vztahy z teorie pravděpodobnosti

- Nezávislost:  $A$  a  $B$  jsou nezávislé, právě když

$$P(A \cap B) = P(A)P(B).$$

Odtud pro nezávislé jevy plyne

$$P(A|B) = P(A), P(B|A) = P(B).$$

# Základní pojmy a vztahy z teorie pravděpodobnosti

- Nezávislost:  $A$  a  $B$  jsou nezávislé, právě když

$$P(A \cap B) = P(A)P(B).$$

Odtud pro nezávislé jevy plyne

$$P(A|B) = P(A), P(B|A) = P(B).$$

- Podmíněná nezávislost:  $A$  a  $B$  jsou podmíněně nezávislé za podmínky, že nastal jev  $C$ , právě když platí

$$P(A \cap B|C) = P(A|C)P(B|C).$$

Odtud pro podmíněně nezávislé jevy plyne

$$P(A|B \cap C) = \frac{P(A \cap B \cap C)}{P(B \cap C)} = \frac{P(A|C)P(B|C)P(C)}{P(B|C)P(C)} = P(A|C).$$

$B_1, B_2, \dots, B_n$  - úplný systém vzájemně disjunktních náhodných jevů. Pak platí:

- Věta o úplné pravděpodobnosti:

$$P(A) = \sum_{i=1}^n P(A|B_i)P(B_i) = \sum_{i=1}^n P(A \cap B_i).$$

$B_1, B_2, \dots, B_n$  - úplný systém vzájemně disjunktních náhodných jevů. Pak platí:

- Věta o úplné pravděpodobnosti:

$$P(A) = \sum_{i=1}^n P(A|B_i)P(B_i) = \sum_{i=1}^n P(A \cap B_i).$$

- Bayesova věta:

$$P(B_i|A) = \frac{P(A|B_i)P(B_i)}{P(A)} = \frac{P(A|B_i)P(B_i)}{\sum_{i=1}^n P(A|B_i)P(B_i)}.$$

# Základní pojmy a vztahy z teorie pravděpodobnosti

$X, Y, Z$  - náhodné veličiny se sdruženou hustotou pravděpodobnosti  $f_{X,Y,Z}(x, y, z)$ ,  $f_{X,Y,Z}(x, y, z) > 0$

- Marginalizace:

$$f_X(x) = \int f_{X,Y}(x, y) dy.$$

# Základní pojmy a vztahy z teorie pravděpodobnosti

$X, Y, Z$  - náhodné veličiny se sdruženou hustotou pravděpodobnosti  $f_{X,Y,Z}(x, y, z)$ ,  $f_{X,Y,Z}(x, y, z) > 0$

- Marginalizace:

$$f_X(x) = \int f_{X,Y}(x, y) dy.$$

- Podmíněná hustota pravděpodobnosti náhodné veličiny  $X$  za podmínky  $Y = y$ :

$$f_{X|Y}(x|y) = \frac{f_{X,Y}(x, y)}{f_Y(y)}.$$

Odtud plyne

$$f_{X,Y}(x, y) = f_{X|Y}(x|y)f_Y(y).$$



- Řetězové pravidlo:

$$f_{X,Y,Z}(x, y, z) = f_{X|Y,Z}(x|y, z)f_{Y|Z}(y|z)f_Z(z)$$

- Řetězové pravidlo:

$$f_{X,Y,Z}(x, y, z) = f_{X|Y,Z}(x|y, z)f_{Y|Z}(y|z)f_Z(z)$$

- Nezávislost: Náhodné veličiny  $X$  a  $Y$  jsou nezávislé, právě když

$$f_{X,Y}(x, y) = f_X(x)f_Y(y).$$

Odtud pro nezávislé veličiny plyne

$$f_{X|Y}(x|y) = f_X(x).$$

- Náhodné veličiny  $X$  a  $Y$  jsou podmíněně nezávislé za podmínky  $Z = z$ , právě když platí

$$f_{X,Y|Z}(x, y|z) = f_{X|Z}(x|z)f_{Y|Z}(y|z).$$

Odtud pro podmíněně nezávislé veličiny plyne

$$f_{X|Y,Z}(x|y, z) = f_{X|Z}(x|z).$$

- Náhodné veličiny  $X$  a  $Y$  jsou podmíněně nezávislé za podmínky  $Z = z$ , právě když platí

$$f_{X,Y|Z}(x,y|z) = f_{X|Z}(x|z)f_{Y|Z}(y|z).$$

Odtud pro podmíněně nezávislé veličiny plyne

$$f_{X|Y,Z}(x|y,z) = f_{X|Z}(x|z).$$

- Bayesův vzorec:

$$f_{X|Y}(x|y) = \frac{f_{Y|X}(y|x)f_X(x)}{f_Y(y)} = \frac{f_{Y|X}(y|x)f_X(x)}{\int f_{Y|X}(y|x)f_X(x)dx}.$$

# Bayesovská rozhodovací úloha

Model, apriorní hustota, aposteriorní hustota

Neznámé veličiny v úloze jsou považovány za náhodné.

- Systém popsany náhodnými veličinami  $x, \theta$ 
  - $x$  ... pozorovatelná veličina, data
  - $\theta$  ... neznámý parametr
- Pravděpodobnostní model  $f(x|\theta)$ 
  - závislost  $x$  na neznámém parametru  $\theta$
  - podmíněná hustota pravděpodobnosti
- **Apriorní hustota pravděpodobnosti**  $f(\theta)$ 
  - informace o parametru  $\theta$  dostupné předem
- **Aposterioorní hustota pravděpodobnosti**  $f(\theta|x)$

$$f(\theta|x) = \frac{f(x|\theta)f(\theta)}{f(x)} = \frac{f(x|\theta)f(\theta)}{\int f(x|\theta)f(\theta)d\theta}$$

- celková informace o  $\theta$  (apriorní + inf. z dat)

- Model:
  - nejen běžné statistické modely
  - obecně složitý, např. hierarchický
  - často využívá podmíněných nezávislostí
- Veličiny  $x, \theta$ :
  - obecně vektorové
  - složky závislé
  - veliká dimenze
- Parametr  $\theta$  může mít jakýkoliv význam:
  - parametr statistického modelu
  - nepozorované fyzikální veličiny
  - ...

- explicitně vyjádřená apriorní informace
- charakteristický prvek bayesovských metod
- zdroj apriorní informace:
  - teoretické modely, např. fyzikální
  - expertní zkušenost
  - podobné úlohy
  - omezení
- technicky obtížné, není-li vhodná informace k dispozici
  - neinformativní apriorní hustoty
- Nemám-li apriorní informaci, nemám problém!

- vyjadřuje celkovou informaci o parametru
- zjednodušený zápis

$$f(\theta|x) \propto f(x|\theta)f(\theta),$$

$\propto$  značí úměrnost až na normlizační člen

- normalizační člen určen podmínkou  $\int f(\theta|x)d\theta = 1$
- Bayesův vzorec představuje mechanismus učení.



Předpokládejme:

- $x = (x_1, \dots, x_t)$
- $x_1, \dots, x_t$  nezávislá pozorování
- index ( $\tau$ ) ... čas

apsteriorní hustota v čase  $\tau$ :

$$f(\theta|x_1, \dots, x_\tau) = \frac{f(x_\tau|\theta)f(\theta|x_1, \dots, x_{\tau-1})}{\int f(x_\tau|\theta)f(\theta|x_1, \dots, x_{\tau-1})d\theta}$$

Apsteriorní hustota z předchozího času ( $\tau - 1$ ) slouží v čase  $\tau$  jako apriorní. Učení probíhá sekvenčně.

Cíle rozhodování popsány ztrátovou funkcí.

- množina možných rozhodnutí:  $\mathcal{A}$
- množina hodnot parametru:  $\Theta$

Ztrátová funkce je libovolná funkce

$$L : \mathcal{A} \times \Theta \rightarrow R^+.$$

Rozhodnutí přiřazuje hodnotu ve smyslu ztráty, kterou toto rozhodnutí způsobí v závislosti na hodnotě parametru  $\theta$ .

Příklad: kvadratická ztrátová funkce

$$L(a, \theta) = (a - \theta)^2.$$

# Bayesovská rozhodovací úloha

## Optimální rozhodnutí

Za optimální rozhodnutí  $a^{opt}$  pak považujeme rozhodnutí, které minimalizuje střední hodnotu ztrátové funkce vzhledem k aposterioriornímu rozdělení, tj.

$$a^{opt} \in \underset{a \in \mathcal{A}}{\text{Argmin}} \int L(a, \theta) f(\theta|x) d\theta. \quad (1)$$

- 1 Pro daný problém specifikujeme
  - statistický model:  $f(x|\theta)$ ,
  - apriorní hustotu pravděpodobnosti:  $f(\theta)$ ,
  - množinu rozhodnutí:  $\mathcal{A}$ ,
  - ztrátovou funkci:  $L : \mathcal{A} \times \Theta \rightarrow \mathbb{R}^+$ .
- 2 Optimální rozhodnutí  $a^{opt} \in \mathcal{A}$  hledáme tak, aby splňovalo podmínku

$$a^{opt} \in \underset{a \in \mathcal{A}}{\text{Argmin}} \int L(a, \theta) f(\theta|x) d\theta,$$

kde

$$f(\theta|x) = \frac{f(x|\theta)f(\theta)}{\int f(x|\theta)f(\theta)d\theta}.$$

# Bayesovská rozhodovací úloha

- uvedená formulace pro statické úlohy
- pro dynamické úlohy složitější, ale princip stejný
- výhody bayesovského přístupu:
  - jednoduchá formulace i pro složité úlohy
  - explicitně reprezentována apriorní informace
- nevýhody bayesovského přístupu: všechny dílčí kroky mohou být technicky obtížné
  - tvar aposteriorní hustoty
  - dimenze úlohy
  - optimalizace rozhodovací strategie
- často využívána numerická a suboptimální řešení