

Bayesovská statistika

Petr Šimeček

Podmiňování

Pravděpodobnost jevu A za podmínky, že nastav jev B

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

Obdobně se zavádí pravděpodobnost, že $X = x$ za podmínky $Y = y$

$$p_{X|Y}(x|y) = \frac{p_{X,Y}(x, y)}{p_Y(y)},$$

resp. ve spojitém případě podmíněná hustota

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

Bayesova věta – nejjednodušší tvar

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} = \frac{P(A|B)P(B)}{P(A|B)P(B)+P(A|\text{not}(B))P(\text{not}(B))}$$

Schematicky

posterior = prior × verohodnost

Příklad – lékařská diagnostika

Máme test na rakovinu, která má specifitu a senzitivitu tj.

$$P(+|rakovina) = P(-|zdravy) = 0.95$$

a předpokládáme, že prevalence rakoviny je tzn.

$$P(rakovina) = 0.005$$

Jaká je pravděpodobnost, že máte rakovinu, pokud vám test vyšel pozitivně?

$$P(rakovina|+) = ?$$

Bayesova věta pro náhodné jevy

Nechť A je náhodný jev. Nechť B_1, \dots, B_n je soubor disjunktních náhodných jevů takový, že jejich sjednocení je Ω . Nechť pravděpodobnost A i pravděpodobnost všech B_1, \dots, B_n je nenulová, potom pro libovolné $i = 1, \dots, n$ platí

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

Klasická (frekventistická) statistika

Ideové základy R.A.Fisher (poč. 20. stol.)

- parametry jsou pevné
- testujeme nulovou hypotézu (inspirace Popperovou filosofií), určíme si s jakou psťí jsme ochotni se mýlit

Problémy

- Kdo věří v nulové hypotézy?
- Interpretace, mnohonásobná porovnávání

Bayesovská statistika

- všechno jsou náhodné veličiny
- netestujeme hypotézy, ale děláme intervalové odhady

Problémy

- Kde vzít apriorní rozdělení?
- Ve složitějších případech výpočetně složité (simulace, numerická integrace)

Bayesovská věta pro spojité náhodné veličiny

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

Lze interpretovat jako

- f_Y apriorní informace o parametru Y (předpokládané rozdělení před pokusem) – prior
- $f_{X|Y}$ jak X závisí na parametru Y (obvykle známe) – věrohodnost
- $f_{Y|X}$ jak se změní rozdělení Y – posterior

Příklad – beta a alternativní rozdělení

Máme posloupnost (X) k úspěchů a l neúspěchů, přičemž předpokládáme, že pravděpodobnost úspěchu (Y) je náhodně rozdělená s hustotou $Beta(a, b)$


$$f_Y(y) = \frac{x^{a-1}(1-x)^{b-1}}{B(a, b)}$$

Potom aposteriorní rozdělení má hustotu

$$Beta(a + k, b + l)$$

Příklad – beta a alternativní rozdělení

Uvažujme kupříkladu 10 úspěchů a 4 neúspěchy:



Jiný příklad "konjugované" dvojice

Předpokládáme, že máme pozorování z $N(\mu, \sigma^2)$.

Apriorní rozdělení pro μ budiž také normální $N(\mu_0, \sigma_0^2)$.

Pozorování X_1, \dots, X_n s průměrem m . Potom aposteriorní rozdělení pro μ je opět normální s parametry

$$N \left(\frac{\frac{mn}{\sigma^2} + \frac{\mu_0}{\sigma_0^2}}{\frac{n}{\sigma^2} + \frac{1}{\sigma_0^2}}, \frac{1}{\frac{n}{\sigma^2} + \frac{1}{\sigma_0^2}} \right)$$

Gibb's sampler

Problém – často nejsme schopni rozdělení přesně upočítat. Řešením může být numerická integrace, ale častěji je to simulace.

Situace: Máme nějaké známé veličiny (X) a neznámé (skryté, latentní) Y_1, \dots, Y_n , jejichž rozdělení bychom rádi spočítali.

- Na počátku všechny neznámé veličiny inicializujeme nějakou (vesměs libovolnou) hodnotou $y_1^{(0)}, \dots, y_n^{(0)}$
- V k -tém kroku simulujeme i -tou náhodnou veličinu Y_i podmíněně na X a na všech ostatních veličinách $Y_1 = y_1^{(k)}, \dots, Y_{i-1} = y_{i-1}^{(k)}, Y_{i+1} = y_{i+1}^{(k-1)}, \dots, Y_n = y_n^{(k-1)}$.

Programová implementace

- **WinBUGS** – pro nekomerční použití zdarma po registraci
- **OpenBUGS** – GNU licence, zatím totožný s WinBUGS
- **BRUGS** – knihovna pod R pro OpenBUGS

K čemu je to dobré v Kalmanově filtraci?

Pokud Y_t závisí na X_t nějak jinak než gaussovsky (např. exponenciální rozdělení, poissonovo rozdělení), potom je těžké upočítat Kalmanův filtr. Naopak nemusí být tak těžké spočítat to Bayesovsky, resp. ve složitějším případě z této řady simulovat.