

# Vybrané kapitoly zo štatistickej fyziky

## Príklady z cvičenia

cviko bolo 5.3.2024

Bayesovská štatistika a Markov chains

Akékoľvek otázky smelo smerujte na juraj(a)tekel(b)gmail(c)com

### Bayesov vzorec

$$P(M_i|\mathcal{D}) = \frac{\pi(M_i)P(\mathcal{D}|M_i)}{\sum_i \pi(M_i)P(\mathcal{D}|M_i)},$$

kde  $M_i$  označuje rôzne modely (možnosti),  $\mathcal{D}$  označuje pozorované/nové dáta,  $\pi(M_i)$  označuje našu apriórnu pravdepodobnosť pre daný model (ako veľmi si myslíme, že realita popisovaná modelom  $M_i$ ),  $P(\mathcal{D}|M_i)$  označuje pravdepodobnosť, že dáta  $\mathcal{D}$  sú dôsledkom modelu  $M_i$  a  $P(M_i|\mathcal{D})$  je nové (posteriórne) rozdelenie pravdepodobnosti na možných modeloch, ktoré berie do úvahy nové dáta. Schematicky teda<sup>1</sup>

$$\pi(M_i) \xrightarrow{\mathcal{D}} P(M_i|\mathcal{D}).$$

Tu je kľúčový pohľad na pravdepodobnosť ako na modelovanie nevedomosti. My nevieme, aký model  $M_i$  je v skutočnosti realizovaný a túto nevedomosť modelujeme rozdelením pravdepodobnosti  $\pi$ . Získame o svete nové informácie  $\mathcal{D}$  a rozmýšľame, ako tieto informácie menia našu predstavu o realite.

**Príklad 1** (■ Frekvencionistická minca). Máme mincu, o ktorej si nie sme istý, že je férová. Urobíme teda experiment, mincu  $n$  krát hodíme a dostaneme  $n_1$  krát znak.

- Za akých podmienok o minci vyhlásime, že férová nie je?
- Po koľkých hodoch odhalíme úplne neférovú mincu s  $p = 1$ ?

**Príklad 2** (■ Bayesovská minca). Máme mincu, o ktorej si nie sme istý, že je férová a na overenie tohto faktu urobíme rovnaký experiment ako v predchádzajúcej úlohe. Avšak vyhodnocujeme ho Bayesovsky. To znamená, že na začiatok uvažujeme, že o minci nemáme žiadnu informáciu.

- Čo môžeme na základe experimentu o minci usúdiť?
- Aká bude očakávaná neférovosť mince  $\langle p \rangle$ ? (pre férovú mincu  $p = 1/2$ )
- Ako bude vyzeráť študovanie úplne neférovej mince?

**Príklad 3** (Kruť aktuálny príklad). Nech je špecifita Ag testu 0.99, tj. zdravý človek dostane s pravdepodobnosťou 99% negatívny výsledok a s pravdepodobnosťou 1% pozitívny výsledok. Ďalej nech je senzitivita Ag testu 0.4, tj. chorý človek dostane s pravdepodobnosťou 40% pozitívny výsledok a s pravdepodobnosťou 60% negatívny výsledok.

Najskôr sa zamyslite nad tým, aké sú rozumné rozdelenia apriórnej pravdepodobnosti pre stav človeka, ktorý má príznaky a ktorý nemá príznaky.

Majme teraz človeka, ktorý ide na dva Ag testy za sebou, ktorých výsledky sú

- negatívny, negatívny,
- negatívny, pozitívny,
- pozitívny, negatívny,
- pozitívny, pozitívny.

Čo viete povedať o stave človeka, ktorý bol pôvodne bez príznakov / s príznakmi, po týchto výsledkoch?

**Príklad 4** (FC Beňušovce). Futbalový tím [FC Beňušovce] včera hral víťazný zápas. Ak vieme, že futbalisti tohto tímu hrajú 60% zápasov večer a nočných zápasov vyhrajú 55%, ale denných iba 35%, s akou pravdepodobnosťou bol včerajší zápas večer?

<sup>1</sup>Toto je moje obľúbené vyjadrenie Bayesovho vzorca.

**Príklad 5** (Extrémne neinovatívna úloha na precvičenie). Majme dve vrece s bielymi a čiernymi guľičkami, označené X a Y. Vreca X obsahuje  $p_X = 20\%$  bielych guľičiek a vreca Y obsahuje  $p_Y = 40\%$  bielych guľičiek. Z náhodného vreca vytiahneme 9 guľičiek, z toho 3 biele. S akou pravdepodobnosťou to bolo vreca X?

**Príklad 6** (■ Spresnenie merania). Meranie istej veličiny ukázalo hodnotu 10 so štandardnou odchýlkou 7 (Gaussovské rozloženie). Chceme túto hodnotu spresniť a preto zoberieme merací prístroj, na ktorom sa dočítame, že preň  $\sigma = 4$  a urobíme dve nové merania. Dostaneme výsledky 4 a 6. Čo vieme o hodnote tejto veličiny povedať teraz?

**Príklad 7** (Ups). Meranie hmotnosti častice ukázalo, že jej hmotnosť by mala byť  $(-0.3 \pm 1)eV$ . To ale tak nemôže byť, nakoľko hmotnosť je určite kladná. Aká je očakávaná hmotnosť častice po uvážení tohto faktu?

## Metropolisov algoritmus

**Príklad 8** (Markov chain pre dvojhladinový systém). Majme náhodnú premennú  $x$ , ktorá má dve hodnoty 0 a 1, pričom  $p(0) = p$  a  $p(1) = 1 - p$ . Zostrojme nasledujúcu postupnosť hodnôt náhodnej premennej  $\{x_i\}, i = 1, \dots, N$ . Začneme s nejakou hodnotou  $x_0$ , na základe algoritmu ktorý bude špecifikovaný neskôr zvolíme testovaciu hodnotu  $x_t$  a urobíme pomer

$$\alpha = \frac{p(x_t)}{p(x_0)}. \quad (1)$$

Potom vyberieme náhodné číslo  $q$  z intervalu  $(0, 1)$  a ak  $\alpha \geq q$ , za  $x_1$  zvolíme  $x_t$ , ak  $\alpha < q$  za  $x_1$  zvolíme  $x_0$ . Rovnaký postup opakujeme postupne pre ďalšie  $x_i$ .

Vygenerujte takto niekoľko postupností pre rôzne  $N$  a presvedčte sa, že  $\sum x_i = Np$ .

Potom vygenerujte zoberte z postupnosti iba poslednú hodnotu  $x_N$  a celý postup zopakujte  $M$  krát. Takto dostanete sadu  $M$  čísel  $x_j$  a overte, že opäť platí  $\sum x_j = Np$ .

Ako testovaciu hodnotu  $x_t$  pre vytvorenie  $x_{i+1}$  je v tomto prípade prirodzené zobrať opačnú hodnotu ako je  $x_i$ .

**Príklad 9** (Metropolisov algoritmus ako generátor náhodných čísel). Majme náhodnú premennú  $x$ , ktorá je rozdelená podľa rozdelenia pravdepodobnosti  $p(x)$ . Zostrojme nasledujúcu postupnosť hodnôt náhodnej premennej  $\{x_i\}, i = 1, \dots, N$ . Začneme s nejakou hodnotou  $x_0$ , na základe algoritmu ktorý bude špecifikovaný neskôr zvolíme testovaciu hodnotu  $x_t$  a urobíme pomer

$$\alpha = \frac{p(x_t)}{p(x_0)}. \quad (2)$$

Potom vyberieme náhodné číslo  $q$  z intervalu  $(0, 1)$  a ak  $\alpha \geq q$ , za  $x_1$  zvolíme  $x_t$ , ak  $\alpha < q$  za  $x_1$  zvolíme  $x_0$ . Rovnaký postup opakujeme postupne pre ďalšie  $x_i$ . Dá sa ukázať, že rozdelenie takomto súbore hodnôt  $\{x_i\}$  konverguje k  $p(x)$ , t.j. že vybrať náhodne z tohto súboru je to isté ako vybrať náhodne zo všetkých možných  $x$  podľa rozdelenia pravdepodobnosti  $p(x)$ .

- Rozmyslite si, že pre generovanie postupnosti nepotrebujeme poznať normalizáciu  $p(x)$ . Prečo je to dôležité?
- Rozmyslite si, že pre  $x$  stav v kanonickom súbore a  $p(x)$  príslušné rozdelenie pravdepodobnosti takto dostaneme algoritmus z prednášky.
- Za náhodnú premennú zvolíme celé čísla  $\mathbb{Z}$  a  $x_0 = 0$ . Za algoritmus generovania  $x_t$  zoberme náhodný krok veľkosti 1 vpravo alebo vľavo. Takýto algoritmus vygeneruje pre  $p(x) = e^{-x^2/2}$  postupnosť celých čísel rozdelených podľa Gaussovho rozdelenia. Overte to počítačovým programom. Skúste, ako váš výsledok závisí od voľby  $N$  a ako to vyzerá, keď budete čísla  $x$  voliť na číselnej osi hustejšie.
- Naprogramujte aj dvojrozmerný prípad, pre  $x_1, x_2 \in \mathbb{R}^2$ . Algoritmus generovania testovacieho bodu skúste ako
  - krok náhodným smerom veľkosti 1,
  - krok veľkosti 1 náhodne doprava alebo doľava a potom krok veľkosti 1 náhodne hore alebo dole.

Porovnajte výsledky, fungujú oba spôsoby generovania rovnako dobre?

- e. Vyskúšajte rôzne iné rozdelenia  $p(x)$ , napríklad aj také, kedy neviete nájsť generátor metódou inverzná k primitívnej. Kedy funguje Metropolis lepšie, ako táto metóda?

Treba upozorniť, že táto implementácia je trochu naivná a program môže mať niekoľko problémov, ktoré potom treba riešiť sofistikovanejším postupom.

**Príklad 10** (Metropolisov algoritmus ako gene-

rátor náhodných čísel 2). Iný postup, spomínaný v nasledujúcom príklade, je o čosi iný ako vyššie prezentovaný. Tam sa zoberie ako hodnota náhodnej premennej posledná vygenerovaná premenná  $x_N$  a ďalšia hodnota sa potom generuje novou postupnosťou. Zvoľte  $N_1, N_2$  a upravte váš program tak, aby  $N_2$ -krát vygeneroval postupnosť  $N_1$  náhodných čísel a za výsledný súbor zoberal iba posledné vygenerované premenné. Porovnajte z výsledkom z predchádzajúcej úlohy pre  $N = N_2$ .