

# Pravděpodobnost

Kombinatorika pro bioinformatiky

4.11.2020

## 1 Pravděpodobnostní prostory

**Definice 1** Konečný pravděpodobnostní prostor je trojice  $(\Omega, \mathcal{F}, P)$ , kde  $\Omega$  je konečná množina,  $\mathcal{F} = 2^\Omega$  a  $P : \mathcal{F} \mapsto [0, 1]$  splňující pro každou  $A \subseteq \Omega$

$$P(A) = \sum_{\omega \in A} P(\{\omega\})$$

a  $P(\Omega) = 1$ .

**Příklady pravděpodobnostních prostorů:**

Hod (spravedlivou) mincí:  $\Omega = \{R, L\}$ ,  $P(R) = P(L) = \frac{1}{2}$ .

Hod kostkou:  $\Omega = \{1, 2, 3, 4, 5, 6\}$ ,  $P(k) = \frac{1}{6}$  pro  $k = 1, 2, 3, 4, 5, 6$ .

Opakovaný hod mincí:  $\Omega = \{R, L\}^n$ ,  $P(\omega) = \frac{1}{2^n}$  pro  $\forall \omega \in \{R, L\}^n$ .

Náhodná permutace:  $\Omega = S_n$ ,  $P(\pi) = \frac{1}{n!}$  pro všechny  $\pi \in S_n$ .

**Definice 2** Pravděpodobnostní prostor  $(\Omega, 2^\Omega, P)$  se nazývá uniformní (též klasický) pravděpodobnostní prostor, pokud  $P(A) = \frac{|A|}{|\Omega|}$  pro všechny jevy  $A \subseteq \Omega$ .

## 2 Podmíněná pravděpodobnost

**Definice 3** Jevy  $A$  a  $B$  se nazývají nezávislé, pokud  $P(A \cap B) = P(A) \cdot P(B)$ .  
Obecně, jevy  $A_1, A_2, \dots, A_n$  jsou nezávislé, pokud pro každou (neprázdnou) podmnožinu  $I \subseteq \{1, 2, \dots, n\}$  platí  $P(\bigcap_{i \in I} A_i) = \prod_{i \in I} P(A_i)$ .

**Definice 4** Podmíněná pravděpodobnost jevu  $A$  za předpokladu, že nastal jev  $B$ , se definuje jako

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

(je def. pouze pro  $P(B) > 0$ ).

**Pozorování 5** Jsou-li jevy  $A, B$  nezávislé a  $P(B) > 0$ , pak  $P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{P(A)P(B)}{P(B)} = P(A)$ . A naopak, pokud  $P(A|B) = P(A)$ , jedná se o nezávislé jevy.

**Příklad:** Uvažujme, že v nějaké populaci je četnost bezejmenné choroby 1 osoba z 1000. K dispozici máme test, jehož spolehlivost je 95% (u skutečně nemocné osoby vyjde test s pravděpodobností 95% pozitivně, a taktéž u zdravé osoby vyjde test s pravděpodobností 95% negativně). Jaké je pravděpodobnost, že testovaná osoba je skutečně nemocná, pokud jí vyšel pozitivní test?

Zavedeme si značení:  $N$  bude označovat jev, že daná osoba je nemocná, a  $\bar{N}$  jev, že nemocná není. Analogicky,  $T$  značí pozitivní test a  $\bar{T}$  negativní test. Zadáni pak znamená  $P(N) = \frac{1}{1000}$ ,  $P(T|N) = P(\bar{T}|\bar{N}) = \frac{19}{20}$  a zajímá nás  $P(N|T)$ .

Podle definice podmíněné pravděpodobnosti je

$$P(N|T) = \frac{P(N \cap T)}{P(T)}.$$

Čitatele lze vyjádřit z

$$P(T|N) = \frac{P(T \cap N)}{P(N)}$$

jako

$$P(N \cap T) = P(T|N) \cdot P(N) = \frac{19}{20} \cdot \frac{1}{1000} = \frac{19}{20000}.$$

Jmenovatele v řešeném výrazu spočteme

$$\begin{aligned} P(T) &= P(T|N) \cdot P(N) + P(T|\bar{N}) \cdot P(\bar{N}) = \\ &= P(T|N) \cdot P(N) + (1 - P(\bar{T}|\bar{N})) \cdot P(\bar{N}) = \frac{19}{20} \cdot \frac{1}{1000} + \frac{1}{20} \cdot \frac{999}{1000} = \frac{1018}{20000}. \end{aligned}$$

Nyní již jen dosadíme

$$P(N|T) = \frac{P(N \cap T)}{P(T)} = \frac{\frac{19}{20000}}{\frac{1018}{20000}} = \frac{19}{1018} < \frac{20}{1000} = 0.02.$$

**Věta 6 (Věta o úplné pravděpodobnosti)** *Nechť  $A$  je nějaký jev a  $B_1, \dots, B_n$  jsou disjunkttní jevy pokrývající celé  $\Omega$ , navíc  $P(B_i) > 0$  pro  $i = 1, \dots, n$ . Pak*

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

**Důkaz:** Protože jevy  $B_1, \dots, B_n$  pokrývají  $\Omega$ , platí pro každé  $A$

$$A = \bigcup_{i=1}^n (A \cap B_i) .$$

Z jejich disjunkttnosti plyne, že i členy  $A \cap B_i$  jsou disjunkttní a tedy  $P(A) = \sum_{i=1}^n P(A \cap B_i)$ , což dále upravujeme s využitím vztahu

$$P(A \cap B_i) = P(A|B_i) \cdot P(B_i) .$$

A dotáváme

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

□

**Věta 7 (Bayesova věta)** *Nechť  $A$  je nějaký jev a  $B_1, \dots, B_n$  jsou disjunkttní jevy pokrývající celé  $\Omega$ , navíc  $P(B_i) > 0$  pro  $i = 1, \dots, n$ . Pak*

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

**Důkaz:** Z def. podmíněné pravděpodobnosti vyjádříme pravděpodobnost průniku dvou jevů oběma možnými způsoby

$$P(A \cap B_k) = P(A|B_k) \cdot P(B_k) = P(B_k|A) \cdot P(A)$$

Z toho

$$P(B_k|A) = \frac{P(A|B_k) \cdot P(B_k)}{P(A)}$$

a za jmenovatele zlomku dosadíme z Věty o úplné pravděpodobnosti.

□

**Definice 8** *Součím pravděpodobnostních prostorů  $(\Omega_1, 2^{\Omega_1}, P_1)$  a  $(\Omega_2, 2^{\Omega_2}, P_2)$  je prostor  $(\Omega, 2^\Omega, P)$ , kde  $\Omega = \Omega_1 \times \Omega_2$  a pro  $A \subseteq \Omega$  je*

$$P(A) = \sum_{(\omega_1, \omega_2) \in A} P_1(\{\omega_1\}) \cdot P_2(\{\omega_2\}) .$$

### 3 Náhodné veličiny

**Definice 9** (Reálná) náhodná veličina na konečném pravděpodobnostním prostoru  $(\Omega, 2^\Omega, P)$  je libovolná funkce  $X : \Omega \mapsto \mathbb{R}$ .

**Příklad:** Pro  $n \in \mathbb{N}$  definujeme náhodnou veličinu (používá se též pojmenování náhodná proměnná)  $X_n$  rovnu počtu líců při  $n$  hodech spravedlivou mincí. To znamená, že  $\Omega_n = \{L, R\}^n$  a  $X_n$  nabývá hodnot  $0, 1, \dots, n$ , přičemž

$$P(X_n = k) = \frac{\binom{n}{k}}{2^n} .$$

**Definice 10** Buď  $X : \Omega \mapsto \mathbb{R}$  náhodná veličina na konečném pravděpodobnostním prostoru  $(\Omega, 2^\Omega, P)$ . Střední hodnota  $X$  je definována jako

$$E(X) = \sum_{\omega \in \Omega} P(\{\omega\}) \cdot X(\omega) .$$

**Věta 11 (Linearita střední hodnoty)** Nechtě  $X, Y$  jsou náhodné reálné veličiny na (konečném) pravděpodobnostním prostoru  $(\Omega, 2^\Omega, P)$ ,  $\alpha \in \mathbb{R}$ . Potom

$$\begin{aligned} E(\alpha X) &= \alpha E(X) \\ E(X + Y) &= E(X) + E(Y) \end{aligned}$$

**Důkaz:** Plyne přímo rozepsáním definice:

$$\begin{aligned} E(\alpha X) &= \sum_{\omega \in \Omega} P(\{\omega\}) \cdot (\alpha X)(\omega) = \sum_{\omega \in \Omega} \alpha P(\{\omega\}) \cdot X(\omega) = \\ &= \alpha \sum_{\omega \in \Omega} P(\{\omega\}) \cdot X(\omega) = \alpha E(X) \end{aligned}$$

a

$$\begin{aligned} E(X + Y) &= \sum_{\omega \in \Omega} P(\{\omega\}) \cdot (X + Y)(\omega) = \sum_{\omega \in \Omega} P(\{\omega\}) \cdot (X(\omega) + Y(\omega)) = \\ &= \sum_{\omega \in \Omega} P(\{\omega\}) \cdot X(\omega) + \sum_{\omega \in \Omega} P(\{\omega\}) \cdot Y(\omega) = E(X) + E(Y) . \end{aligned}$$

□

**Definice 12** Indikátor jevu  $A \subseteq \Omega$  je náhodná veličina  $I_A : \Omega \mapsto \{0, 1\}$  definovaná

$$I_A(\omega) = \begin{cases} 1 & \text{pro } \omega \in A \\ 0 & \text{pro } \omega \notin A \end{cases} .$$

**Pozorování 13** Pro střední hodnotu indikátoru platí

$$E(I_A) = P(A) .$$

**Příklad:** Použití indikátorů: Pro náhodnou veličinu z předchozího příkladu (počet líců při  $n$  hodech mincí) spočítejte její střední hodnotu.

Definujme jevy  $A_i$ : při  $i$ -tém hodu padl líc, pro  $i = 1, \dots, n$ . Potom  $P(A_i) = \frac{1}{2}$  pro každé  $i$  a dále  $X_n = \sum_{i=1}^n I_i$  (Pro přehlednější zápis označujeme indikátor jevu  $A_i$  jako  $I_i$ ).

Z toho

$$E(X_n) = E\left(\sum_{i=1}^n I_i\right) = \sum_{i=1}^n E(I_i) = \sum_{i=1}^n P(A_i) = \frac{n}{2} .$$

Poznamejme, že ke stejnému výsledku lze dospět i přímo z definice střední hodnoty, takto je to ale jednodušší.

**Věta 14 (Markovova nerovnost)** Pro nezápornou náhodnou veličinu  $X$  splňující  $E(X) > 0$  a reálné  $t > 1$  platí

$$P(X \geq tE(X)) \leq \frac{1}{t} .$$

**Důkaz:** Nejprve ukážeme, že  $E(X) \geq aP(X \geq a)$  a pak zvolíme vhodnou hodnotu paramtru  $a$ .

Označme  $A \subseteq \Omega$  jev, že hodnota  $X$  je větší rovna  $a$ , tedy  $A = \{\omega \in \Omega \mid X(\omega) \geq a\}$ . Pak

$$\begin{aligned} E(X) &= \sum_{\omega \in \Omega} P(\{\omega\}) \cdot X(\omega) = \sum_{\omega \in A} P(\{\omega\}) \cdot X(\omega) + \sum_{\omega \in \Omega \setminus A} P(\{\omega\}) \cdot X(\omega) \geq \\ &\geq \sum_{\omega \in A} P(\{\omega\}) \cdot a + 0 = a \cdot \sum_{\omega \in A} P(\{\omega\}) = a \cdot P(A) = aP(X \geq a) . \end{aligned}$$

Nyní dosadíme  $a = tE(X)$  a upravíme

$$E(X) \geq (tE(X))P(X \geq tE(X))$$

na požadovaný výsledek

$$P(X \geq tE(X)) \leq \frac{1}{t} .$$

□

**Definice 15** Rozptyl náhodné veličiny  $X$  je definován jako

$$\text{Var}(X) = E((X - E(X))^2) .$$

**Věta 16 (Čebyševova nerovnost)** Pro náhodnou veličinu  $X$  a reálné číslo  $a \geq \sqrt{\text{Var}(X)}$  platí

$$P(|X - E(X)| \geq a) \leq \frac{\text{Var}(X)}{a^2} .$$

**Důkaz:** Uvažme novou náhodnou veličinu  $Y = (X - E(X))^2$ . Dále si uvědomíme, že podmínka  $|X - E(X)| \geq a$  je splněna právě tehdy, když  $(X - E(X))^2 \geq a^2$ , neboli  $Y \geq a^2$ .

Protože  $Y$  je nezáporná náhodná veličina, lze použít Markovovu nerovnost s volbou  $t = \frac{a^2}{\text{Var}(X)}$ . Případ, kdy je  $\text{Var}(X) = 0$ , tedy  $X$  je konstatně rovna  $E(X)$ , si musíme rozmyslet zvlášť, ale Čebyševova nerovnost pak jistě platí.

Markovova nerovnost nám pro  $Y$  dává

$$P(Y \geq tE(Y)) \leq \frac{1}{t} ,$$

kde  $E(Y) = E((X - E(X))^2) = \text{Var}(X)$  a při výše uvedené volbě  $t$  je levá strana

$$\begin{aligned} P(Y \geq tE(Y)) &= P((X - E(X))^2 \geq \frac{a^2}{\text{Var}(X)} \cdot \text{Var}(X)) = P((X - E(X))^2 \geq a^2) = \\ &= P(|X - E(X)| \geq a) \end{aligned}$$

a pravá strana je rovna

$$\frac{1}{t} = \frac{\text{Var}(X)}{a^2} .$$

Tím je důkaz hotov.

□