

Pravděpodobnost

Kombinatorika pro bioinformatiky

4.11.2020

1 Pravděpodobnostní prostory

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

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

$$\text{a } P(\Omega) = 1.$$

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 $k = 1, 2, 3, 4, 5, 6$.

Opakováný 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. Zadání 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 disjunktní jevy pokrývající celé Ω , 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 Ω , platí pro každé A

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

Z jejich disjunktnosti plyne, že i členy $A \cap B_i$ jsou disjunktní 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 disjunktní jevy pokrývající celé Ω , 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 Součin 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 minci. To zamená, 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 Bud' $X : \Omega \mapsto \mathbb{R}$ 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) Nechť 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) spočtěte její střední hodnotu.

Definujme jevy A_i : při i -tému 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 stejnemu 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 $A = \{\omega \in \Omega | X(\omega) \geq a\}$. 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 náhoné veličiny X je definován jako

$$Var(X) = E((X - E(X))^2) .$$

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

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

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 $t = \frac{a^2}{Var(X)}$. Případ, kdy je $Var(X) = 0$, 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 $E(Y) = E((X - E(X))^2) = Var(X)$ a při výše uvedené volbě t je levá strana

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

a pravá strana je rovna

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

Tím je důkaz hotov. □