

Základy teorie pravděpodobnosti

Zdeněk Dvořák

14. listopadu 2018

Příklad 1. *Hrajete ruletu, sázíte vždy na červenou. Před každým kolem si zvolíte výši sázky h , pokud padne červené číslo, získáte h korun, jinak h korun prohrájete. Pravděpodobnost výhry je $18/37 \approx 48.6\%$.*

Máte následující strategii: v prvním kole vsadíte 1 korunu. V dalších kolech, pokud jste v předchozím kole prohráli, zdvojnásobíte sázku, jinak vsadíte 1 korunu. Nechť V označuje vaši výhru po 5 kolech.

Rozdělení V :

v	5	4	3	2	1	0	-1	-2	-5	-6	-14	-31
$P[V = v]$	2.72	11.51	21.09	21.93	13.00	6.42	6.41	3.38	3.20	3.38	3.38	3.57

Tedy s pravděpodobností 70.75% vyhrájete (ale málo), s pravděpodobností jen 23.32% prohrájete (ale hodně).

Střední hodnota je -0.28 Kč: budeme-li tuto strategii opakovat n -krát pro dost velké n , prohrájeme zhruba $0.28n$ Kč.

Pro nezáporné veličiny lze alespoň pomocí střední hodnoty omezit pravděpodobnost, že veličina je příliš velká.

Lemma 1 (Markovova nerovnost). *Pro náhodnou veličinu $X \geq 0$ se střední hodnotou $E[X] = m > 0$ platí pro každé reálné číslo $t \geq 1$*

$$P[X \geq tm] \leq \frac{1}{t}.$$

Důkaz.

$$\begin{aligned} P[X \geq tm] &= \sum_{z \in \Omega, X(z) \geq tm} P[z] \leq \sum_{z \in \Omega, X(z) \geq tm} P[z] \cdot \frac{X[z]}{tm} \\ &\leq \sum_{z \in \Omega} P[z] \cdot \frac{X[z]}{tm} = \frac{1}{tm} E[X] = \frac{1}{t}. \end{aligned}$$

□

Příklad 2. Mějme n bodů v rovině (v obecné poloze) a mezi každými dvěma z nich nakresleme úsečku nezávisle s pravděpodobností $10/n$. Střední hodnota počtu T trojúhelníků (tvořených třemi ze zadaných bodů) je

$$E[T] = \binom{n}{3} \cdot \frac{1000}{n^3} \leq 1000/6.$$

Pravděpodobnost, že vznikne alespoň 1000 trojúhelníků, je tedy

$$P[T \geq 1000] \leq P[T \geq 6 \cdot E[T]] \leq 1/6.$$

Dolní odhad se pouze ze střední hodnoty zjistit nedá (a ve skutečnosti je tato pravděpodobnost mnohem nižší, než $1/6$).

1 Rozptyl a Čebyševova nerovnost

Rozptyl náhodné veličiny X je definován jako

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

Příklad 3. Hrajeme ruletu, vsadíme h na červenou (pravděpodobnost výhry $p = 18/37$). Výše výhry V_h má střední hodnotu

$$E[V_h] = ph + (1 - p)(-h) = (2p - 1)h \approx -0.03h$$

a rozptyl

$$\begin{aligned} \text{Var}[V_h] &= E[(V_h - (2p - 1)h)^2] = p(h - (2p - 1)h)^2 + (1 - p)(-h - (2p - 1)h)^2 \\ &= (p(2 - 2p)^2 + (1 - p)(-2p)^2)h^2 = 4p(1 - p)h^2 \approx h^2. \end{aligned}$$

Pozorování 2. Jestliže $|X| \leq s$, pak $\text{Var}[X] \leq s^2$.

Věta 3 (Čebyševova nerovnost). Pro náhodnou veličinu $X \geq 0$ se střední hodnotou $E[X] = m$ platí pro každé reálné číslo $t \geq 1$

$$P[|X - m| \geq t\sqrt{\text{Var}[X]}] \leq \frac{1}{t^2}.$$

Důkaz. Uvažujme náhodnou veličinu $Y = (X - m)^2$; ta je zjevně nezáporná a její střední hodnota je rovna $s = \text{Var}[X]$. Z Markovovy nerovnosti máme

$$P[|X - m| \geq t\sqrt{\text{Var}[X]}] = P[Y \geq t^2 s] \leq \frac{1}{t^2}.$$

□

Náhodné veličiny X a Y jsou nezávislé, jestliže pro všechna reálná čísla v_x a v_y jsou jevy $X = v_x$ a $Y = v_y$ nezávislé. Například: výše výhry v různých kolech rulety (jestliže sázky zvolíme předem).

Lemma 4. *Jestliže jsou jevy X_1 a X_2 nezávislé, pak*

$$E[X_1 X_2] = E[X_1]E[X_2].$$

Jestliže jsou jevy X_1, \dots, X_n po dvou nezávislé, pak

$$\text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i].$$

Důkaz. Máme

$$\begin{aligned} E[X_1]E[X_2] &= \left(\sum_{v_1} P[X_1 = v_1]v_1\right) \cdot \left(\sum_{v_2} P[X_2 = v_2]v_2\right) \\ &= \sum_{v_1, v_2} P[X_1 = v_1]P[X_2 = v_2]v_1v_2 = \sum_{v_1, v_2} P[X_1 = v_1, X_2 = v_2]v_1v_2 \\ &= \sum_v P[X_1 X_2 = v]v = E[X_1 X_2]. \end{aligned}$$

Nechť $m_i = E[X_i]$ a $m = \sum_{i=1}^n m_i = E(\sum_{i=1}^n X_i)$. Označme $Y_i = X_i - m_i$, takže $E[Y_i] = 0$, $\text{Var}[X_i] = E[Y_i^2]$, a veličiny Y_1, \dots, Y_n jsou po dvou nezávislé. Máme

$$\begin{aligned} \text{Var}\left[\sum_{i=1}^n X_i\right] &= E\left[\left(\sum_{i=1}^n X_i - m\right)^2\right] \\ &= E\left[\left(\sum_{i=1}^n (X_i - m_i)\right)^2\right] = E\left[\left(\sum_{i=1}^n Y_i\right)^2\right] \\ &= E\left[\sum_{i=1}^n Y_i^2 + 2\sum_{i<j} Y_i Y_j\right] = \sum_{i=1}^n E[Y_i^2] + 2\sum_{i<j} E[Y_i]E[Y_j] \\ &= \sum_{i=1}^n E[Y_i^2] = \sum_{i=1}^n \text{Var}[X_i]. \end{aligned}$$

□

Důsledek 5 (Centrální limitní věta, slabá verze). *Nechť X_1, \dots, X_n jsou nezávislé jevy a $\text{Var}[X_i] \leq s^2$ pro $i = 1, \dots, n$. Nechť $X = \sum_{i=1}^n X_i$ a $h = E[X]$. Pak pro každé $t \geq 1$*

$$P(|X - h| \geq ts\sqrt{n}) \leq \frac{1}{t^2}.$$

Důkaz. Dle Lemma 4 máme $\text{Var}[X] = \sum_{i=1}^n \text{Var}[X_i] \leq ns^2$, výsledek plyne z Čebyševovy věty. \square

Příklad 4. *Hodíme n -krát spravedlivou mincí. Jev I_{rub} má střední hodnotu $1/2$ a rozptyl nejvýše 1 dle Pozorování 2. Pravděpodobnost, že rub padne více než $(n/2 + 10\sqrt{n})$ -krát nebo méně než $(n/2 - 10\sqrt{n})$ -krát je tedy nejvýše 1%.*

Příklad 5. *V kasínu je strop na sázky $s = 32$ Kč a minimální sázka 1 Kč. Hráč postupně sází částky $1 \leq h_1, \dots, h_n \leq s$ na červenou (sázky jsou zvolené předem, nezávisí na výhrách v jednotlivých kolech). Označme $h = \sum_{i=1}^n h_i$. Nechť V_i je výhra v i -tém kole a $V = \sum_{i=1}^n V_i$ je celková výhra. V minulém příkladu jsme určili $E[V_i] = (2p - 1)h_i$, a proto $E[V] = (2p - 1)h$. Dále $\text{Var}[V_i] \leq h_i^2 \leq s^2$ dle Pozorování 2. Výhry v jednotlivých kolech jsou nezávislé, proto pravděpodobnost, že $V \geq 0$ (tedy že kasíno na hráči nevydělá) je*

$$\begin{aligned} P[V \geq 0] &= P[V - E[V] \geq |E[V]|] \leq P[|V - E[V]| \geq |E[V]|] \\ &= P\left[|V - E[V]| \geq \frac{|E[V]|}{s\sqrt{n}} \cdot s\sqrt{n}\right] \leq \frac{s^2n}{(E[V])^2} \\ &= \frac{s^2n}{(1 - 2p)^2h^2} \leq \frac{s^2}{(1 - 2p)^2n} = \frac{1401856}{n}. \end{aligned}$$

Tedy, budete-li hrát dost dlouho, skoro jistě prohraje (výrazně dříve, než naznačuje tento hrubý odhad!).