

Poznámky k předmětu Aplikovaná statistika, 3.téma

3. Charakteristiky náhodých veličin

Při praktické práci s daty často na začátku nemůžeme tušit, z jakého rozdělení (resp. jaké jsou parametry daného rozdělení) naše data pocházejí. Je proto dobré si nejprve udělat o datech určitou představu podle některých typických číselných údajů. Na základě dat samozřejmě získáme jen orientační představu o tom, jakých hodnot číselné charakteristiky nabývají. V této kapitole se budeme věnovat teoretickým číselným charakteristikám svázaným s rozdělením náhodné veličiny, nikoliv jejich odhadům!

- **Střední hodnota náhodné veličiny** (značíme $\mathbb{E}X, \mu$)

patří mezi tzv. *míry polohy*. Udává „očekávanou“ hodnotu, okolo které by se měla veličina pohybovat.

Pro **diskrétní** náhodnou veličinu s pravděpodobnostní funkcí $p(\cdot)$ definujeme střední hodnotu následovně:

$$\mathbb{E}X = \sum_i x_i \cdot p(x_i).$$

Pro **spojitou** náhodnou veličinu s hustotou f potom vzorcem

$$\mathbb{E}X = \int_{\mathbb{R}} x \cdot f(x) dx.$$

VLASTNOSTI STŘEDNÍ HODNOTY

1. $\mathbb{E}(aX + b) = a\mathbb{E}X + b, a, b \in \mathbb{R}$,
2. pro náhodné veličiny X, Y platí: $\mathbb{E}(X + Y) = \mathbb{E}X + \mathbb{E}Y$,
3. pokud $\mathbb{P}(X \geq 0) = 1$, pak $\mathbb{E}X \geq 0$.

Poznámka 1. Právě s pojmem střední hodnoty souvisí ony mediální informace typu „průměrný Čech vypije tolík a tolík piva“ (za rok 2015 to bylo 146,6 l na osobu), „průměrný plat v České republice je...“ (ve třetím čtvrtletí 2016 to bylo 27 220 Kč) a tak dále. Čtenář sám si jistě ve škole počítal, jaká známka mu vychází na vysvědčení, a pak se občas divil, že tomu výsledek od pedagoga neodpovídá. Je třeba si uvědomit, že samotná informace o tom, kolem které hodnoty se nám něco pohybuje, není dostatečně vypovídající. Jeden příklad ze života za všechny. Kamarádka hraje stolní tenis v mužské lize (protože je tak dobrá). A po jednom kole nám vyprávěla, že jsme se minule měly přijít podívat na soupeře – věkový průměr třicet (v době vzniku tohoto textu pro autorky věk velmi aktuální), čili lákavá podívaná. Ovšem pouze do okamžiku, než z ní vypadlo, že jednomu soupeři bylo sedmdesát a dvěma dalším deset. Něco takového prostě neumíme detektovat pomocí měr polohy. Je třeba přidat ještě alespoň jednu základní míru variability, rozptyl.

- **Rozptyl náhodné veličiny** (značíme $\text{var}X, \sigma^2$)

patří mezi *míry variability*. V podstatě nám říká, jaká je očekávaná druhá mocnina vzdálenosti náhodné veličiny od její střední hodnoty.

Nechť $-\infty < \mathbb{E}X < \infty$. Potom rozptyl (pro diskrétní i spojitou náhodnou veličinu) definujeme jako

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

Místo tohoto vzorce se v praxi k výpočtu používá vzorce

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

Tzv. *druhý moment*, tj. $\mathbb{E}X^2$, vypočteme pro diskrétní náhodnou veličinu pomocí vzorce

$$\mathbb{E}X^2 = \sum_i x_i^2 \cdot p(x_i),$$

a pro spojitu náhodnou veličinu pomocí analogického vzorce

$$\mathbb{E}X^2 = \int_{\mathbb{R}} x^2 \cdot f(x)dx.$$

Obecně, pokud chceme vypočítat střední hodnotu funkce g náhodné veličiny X , můžeme použít následující vzorce:

$$\begin{aligned}\mathbb{E} g(X) &= \sum_i g(x_i) \cdot p(x_i), & X \text{ diskrétní n.v.,} \\ \mathbb{E} g(X) &= \int_{\mathbb{R}} g(x) \cdot f(x)dx, & X \text{ spojitá n.v.}\end{aligned}$$

Podobně jako v případě střední hodnoty si uvedeme základní vlastnosti rozptylu. Některé další vlastnosti si uvedeme až později, neboť je pro ně nutné zavedení dalších pojmu.

VLASTNOSTI ROZPTYLU

1. $\text{var}X > 0$ pro nedegenerovanou náhodnou veličinu (ale i pro degenerovanou platí $\text{var}X \geq 0$),
2. $\text{var}(a + bX) = b^2 \text{var}X$, $a, b \in \mathbb{R}$.

Ještě než se podíváme na další charakteristiky, uvedeme si pojem **normované náhodné veličiny**. Uvažujme nejprve veličinu X se střední hodnotou $\mathbb{E}X$ a rozptylem $0 < \text{var}X < \infty$. Nyní definujme náhodnou veličinu

$$X_N = \frac{X - \mathbb{E}X}{\sqrt{\text{var}X}}.$$

Náhodná veličina X_N má stejný typ rozdělení jako původní veličina X , ale má, jak čtenář může snadno nahlédnout, nulovou střední hodnotu a jednotkový rozptyl. Veličinu X_N nazýváme *normovaná*.

- **Směrodatná odchylka** (značíme σ)

je tzv. *mírou statistické disperze*, zhruba udává, jak moc je náhodná veličina odchýlena od své střední hodnoty. Je definována jako

$$\sigma = \sqrt{\text{var}X}.$$

- **Kvantily rozdělení náhodné veličiny**

Nyní se omezíme pouze na náhodné veličiny, jejichž distribuční funkce je spojitá a rostoucí na intervalu, kde $F(x) \neq 0$ a $F(x) \neq 1$. Potom **α -kvantilem** (nebo též **$\alpha\%$ -kvantilem**), $\alpha \in (0, 1)$, rozumíme takové číslo u_α , že

$$\mathbb{P}(X \leq u_\alpha) = \alpha.$$

Jinými slovy řečeno je α -kvantil takové reálné číslo, pod něž se soustředí α % hmoty celé pravděpodobnosti.

Poznámka 2. Předpoklady uvedené pro distribuční funkci jsou nezbytné, chceme-li mít zajištěnou jednoznačnost kvantilu. Jsou-li splněny, je funkce $u : \alpha \mapsto u_\alpha$ inverzní funkce k distribuční funkci F . V praktických statistických úlohách se v tomto kurzu stejně jinými rozděleními než těmi, co splňují dané podmínky, zabývat nebudeme.

NĚKTERÉ VÝZNAMNÉ KVANTILY

- $u_{0,25}$ … 1. kvartil,
- $u_{0,5}$ … 2. kvartil, tzv. **medián**,
- $u_{0,75}$ … 3. kvartil.

Cvičení k tomuto tématu

- (i) Náhodná veličina X udává počet lvů, kteří padnou při hodu čtyřmi mincemi. Stanovte pravděpodobnostní funkci $p(x_i) = \mathbb{P}(X = x_i)$ náhodné veličiny X , její střední hodnotu, rozptyl a směrodatnou odchylku.
- (ii) Hlídač přichází do skladu náhodně vždy jednou během 24 hodin. Modelujme jeho příchody náhodnou veličinou X . Určete její hustotu, distribuční funkci (nakreslete také jejich grafy), $\mathbb{E}X$, $\text{var}X$, $\sqrt{\text{var}X}$ a 95% kvantil.
- (iii) Náhodná veličina X je dána distribuční funkcí F v tabulce

x	$(-\infty, -2)$	$[-2, -1]$	$[-1, 0)$	$[0, 2)$	$[2, 3)$	$[3, +\infty)$
$F(x)$	0	0,3	0,5	0,6	0,9	1
- (iv) Nakreslete graf F , zrekonstrujte pravděpodobnostní funkci $p(x_i)$, a pak určete $\mathbb{E}X$, $\text{var}X$, $\sqrt{\text{var}X}$, $\mathbb{P}(X \in [-1, 2])$ a $\mathbb{P}(1 \leq X < 6)$.
- (v) Náhodná veličina X je zadána distribuční funkcí

$$F(x) = \begin{cases} 0 & , \quad x < 1, \\ \log x & , \quad x \in [1, 10], \\ 1 & , \quad x > 10. \end{cases}$$

Nakreslete graf F , stanovte hustotu f náhodné veličiny X (včetně jejího grafu). Dále spočtěte $\mathbb{E}X$, $\text{var}X$, $\sqrt{\text{var}X}$, kvartily a $\mathbb{P}(X > \sqrt[3]{10})$.

- (vi) Náhodná veličina X je dána hustotou

$$f(x) = \begin{cases} \frac{1}{x^2} & , \quad x \in [1, +\infty), \\ 0 & , \quad \text{jinak.} \end{cases}$$

Stanovte distribuční funkci, $\mathbb{E}X$, $\text{var}X$ a všechny kvartily.

- (vii) Náhodná veličina X je zadána hustotou

$$f(x) = \begin{cases} \frac{1}{x^3} & , \quad x \in [\frac{1}{\sqrt{2}}, +\infty), \\ 0 & , \quad \text{jinak.} \end{cases}$$

Spočtěte $\mathbb{E}X$ a $\text{var}X$.

(dcv) Náhodná veličina X je dána hustotou

$$f(x) = \begin{cases} \frac{2}{3}x & , \quad x \in [0, 1), \\ 1 - \frac{1}{3}x & , \quad x \in [1, 3], \\ 0 & , \quad \text{jinde.} \end{cases}$$

Nakreslete graf f a spočtěte

- (a) $\mathbb{P}(X < 1)$, $\mathbb{P}(X > 1)$,
- (b) $\mathbb{E}X$, $\text{var}X$, $\sqrt{\text{var}X}$,
- (c) distribuční funkci náhodné veličiny X ,
- (d) kvantily $u_{0,1}$, $u_{0,5}$ a $u_{0,9}$.