

ZADÁNÍ 13. CVIČENÍ, PODZIM 2019  
POPISNÁ STATISTIKA, NEROVNOSTI, LIMITNÍ VĚTY

**Exponenciální rozdělení**  $\text{Exp}(\lambda)$  je rozdělení s hustotou

$$f(x) = \begin{cases} 0 & \text{for } x < 0, \\ \lambda e^{-\lambda x} & \text{for } x \geq 0. \end{cases}$$

**Markovova nerovnost.** Pro libovolnou nezápornou náhodnou veličinu  $X$  se střední hodnotou  $E(X)$  platí

$$P(X \geq \varepsilon) \leq \frac{E(X)}{\varepsilon}$$

pro všechna  $\varepsilon > 0$ .

**Čebyševova nerovnost.** Pro libovolnou náhodnou veličinu  $X$  se střední hodnotou  $E(X)$  a rozptylem  $D(X)$  platí

$$P(X - E(X)) \geq \varepsilon \leq \frac{D(X)}{\varepsilon^2}$$

nebo ekvivalentně

$$P(X - E(X)) < \varepsilon \geq 1 - \frac{D(X)}{\varepsilon^2}$$

pro všechna  $\varepsilon > 0$ .

**Centrální limitní věta.** Uvažujme posloupnost nezávislých náhodných veličin  $X_i$ , které mají společnou střední hodnotu  $E X_i = \mu$ , společný rozptyl  $\text{var } X_i = \sigma^2 > 0$  a stejně omezený třetí absolutní moment  $E|X_i| < C$ . Pro rozdělení náhodných veličin

$$S_n = \sum_{i=1}^n \frac{X_i - \mu}{\sqrt{n}\sigma}$$

platí limitní vztah

$$\lim P(S_n \leq x) = \Phi(x),$$

kde  $\Phi$  je distribuční funkce normovaného normálního rozdělení  $N(0, 1)$ .

**Moivreova-Laplaceova věta** je speciálním případem centrální limitní věty: Necht'  $X_n$  jsou náhodné veličiny s binomickým rozdělením  $\text{Bi}(n, p)$ . Pak pro normované náhodné veličiny

$$S_n = \frac{X_n - np}{\sqrt{np(1-p)}}$$

platí vztah

$$\lim_{n \rightarrow \infty} P(S_n \leq x) = \Phi(x),$$

kde  $\Phi$  je distribuční funkce normovaného normálního rozdělení  $N(0, 1)$ .

**Příklad 1.** Byly naměřeny následující hodnoty nějakého znaku

10; 7; 7; 8; 8; 9; 10; 9; 4; 9; 10; 9; 11; 9; 7; 8; 3; 9; 8; 7.

Určete aritmetický průměr, medián, kvartily, rozptyl.

**Příklad 2.** Mějme nezápornou náhodnou veličinu  $X$  se střední hodnotou  $\mu$ .

- (1) Bez dalších informací o rozdělení  $X$  odhadněte  $P(X > 3\mu)$ .
- (2) Víte-li, že  $X \sim \text{Ex}(\frac{1}{\mu})$ , vypočtete  $P(X > 3\mu)$ .

**Příklad 3.** Určete pravděpodobnost, že při 1200 hodech kostkou padne šestka alespoň 150 krát a nejvýše 250 krát

- pomocí Čebyševovy nerovnosti,
- pomocí de Moivreovy-Laplaceovy věty.

**Příklad 4.** Průměrná rychlost větru je na určitém místě 20 km/hod.

- Bez ohledu na rozdělení rychlosti větru jako náhodné veličiny určete pravděpodobnost, že při jednom pozorování rychlost větru nepřesáhne 60 km/h.
- Určete interval, v němž se bude rychlost větru nacházet s pravděpodobností alespoň 0,9, víte-li navíc, že směrodatná odchylka  $\sigma = 1$  km/hod.

**Příklad 5.** Na FI je 10% studentů s prospěchem do 1,2. Jak velkou skupinu je třeba vybrat, aby s pravděpodobností 0,95 v ní bylo 8-12% studentů s prospěchem do 1,2? Úlohu řešte zvlášť pomocí Čebyševovy a zvlášť pomocí Moivreovy-Laplaceovy věty.

**Příklad 6.** Dokažte, že pro kvantily normovaného normálního rozdělení platí vztah

$$-u_{\frac{\alpha}{2}} = u_{1-\frac{\alpha}{2}}.$$

**Příklad 7.** Pravděpodobnost, že se zasazený strom ujme, je 0,8. Jaká je pravděpodobnost, že z 500 zasazených stromů se jich ujme aspoň 380?

Výsledek. 0,987.

**Příklad 8.** Pravděpodobnost, že semeno vyklíčí, je 0,9. Kolik semen je třeba zasadit, aby s pravděpodobností aspoň 0,995 vyklíčilo cca 90% semen (což přesněji formulujeme se zpřesňujícím požadavkem, aby odchylka podílu vyklíčených semen od 0,9 nepřevýšila 0,034).

Výsledek.  $n \approx 614$ .

**Příklad 9.** Životnost (v hodinách) určité elektrické součástky má exponenciální rozdělení s parametrem  $\lambda = \frac{1}{10}$ . Pomocí centrální limitní věty odhadněte pravděpodobnost, že celková životnost 100 takových součástek bude mezi 900 a 1050 hodinami.

Výsledek.  $\mu = 10, \sigma^2 = 100, P(900 \leq \sum X_i \leq 1050) = P\left(\frac{900-n\mu}{\sigma\sqrt{n}} \leq \frac{\sum X_i - n\mu}{\sigma\sqrt{n}} \leq \frac{1050-n\mu}{\sigma\sqrt{n}}\right) = \Phi(0,5) - \Phi(-1) \approx 0,533$ .

## NÁHODNÝ VÝBĚR Z NORMÁLNÍHO ROZDĚLENÍ

**Náhodným výběrem rozsahu  $n$**  rozumíme  $n$ -tici nezávislých náhodných veličin  $X_1, \dots, X_n$ , které mají totéž rozdělení. S náhodným výběrem se obvykle setkáváme při opakovaném provádění téhož pokusu.

**Statistika** je náhodná veličina vzniklá transformací náhodného výběru.

- Výběrový průměr  $M = \frac{1}{n} \sum_{i=1}^n X_i$ , a jsou-li navíc  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ , pak  $M \sim N(\mu, \sigma^2/n)$ .
- Výběrový rozptyl  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M)^2 = \frac{1}{n-1} (\sum_{i=1}^n X_i^2 - nM^2)$ ,  $S = \sqrt{S^2}$ .

**Intervalovým odhadem parametru  $\theta$**  rozumíme interval  $(T_L, T_U)$ , kde  $T_L(X_1, \dots, X_n)$  a  $T_U(X_1, \dots, X_n)$  jsou statistiky výběru  $(X_1, \dots, X_n)$ . Platí-li

$$P(T_L \leq \theta \leq T_U) = 1 - \alpha,$$

říkáme, že  $(T_L, T_U)$  je  $100 \cdot (1 - \alpha)\%$  interval spolehlivosti pro parametr  $\theta$ .

**Horním odhadem** parametru  $\theta$  na hladině významnosti  $1 - \alpha$  je statistika  $U$ , pro niž

$$P(\theta < U) \geq 1 - \alpha.$$

Dolním odhadem  $\theta$  na hladině významnosti  $1 - \alpha$  je pak statistika  $L$ , pro niž

$$P(L < \theta) \geq 1 - \alpha.$$

**Případ, kdy je  $X_1, \dots, X_n$  náhodný výběr z normálního rozdělení  $N(\mu, \sigma^2)$ :**

- $M$  a  $S^2$  jsou nezávislé náhodné veličiny.
- $M \sim N(\mu, \sigma^2/n)$ , a tedy  $U = (M - \mu)/(\sigma/\sqrt{n}) \sim N(0, 1)$ .
- $K = (n - 1)S^2/\sigma^2 \sim \chi^2(n - 1)$ .
- $\sum(X_i - \mu)^2/\sigma^2 \sim \chi^2(n)$ .
- $T = (M - \mu)/(S/\sqrt{n}) \sim t(n - 1)$ .

**Intervaly spolehlivosti:**

$\mu$ (známe $\sigma^2$ )	$(M - \frac{\sigma}{\sqrt{n}}u_{1-\alpha/2}, M + \frac{\sigma}{\sqrt{n}}u_{1-\alpha/2})$
$\mu$ (neznáme $\sigma^2$ )	$(M - \frac{S}{\sqrt{n}}t_{1-\alpha/2}(n-1), M + \frac{S}{\sqrt{n}}t_{1-\alpha/2}(n-1))$
$\sigma^2$ (neznáme $\mu$ )	$(\frac{(n-1)S^2}{\chi_{1-\alpha/2}^2(n-1)}, \frac{(n-1)S^2}{\chi_{\alpha/2}^2(n-1)})$
$\sigma^2$ (známe $\mu$ )	$(\frac{\sum(X_i - \mu)^2}{\chi_{1-\alpha/2}^2(n)}, \frac{\sum(X_i - \mu)^2}{\chi_{\alpha/2}^2(n)})$
$\mu_1 - \mu_2$ (známe $\sigma_1^2, \sigma_2^2$ )	$M_1 - M_2 \pm \sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}} \cdot u_{1-\alpha/2}$
$\mu_1 - \mu_2$ (neznáme $\sigma_1^2 = \sigma_2^2$ )	$M_1 - M_2 \pm S_* \sqrt{\frac{1}{m} + \frac{1}{n}} \cdot t_{1-\alpha/2}(m+n-2)$
podíl rozptylů $\sigma_1^2/\sigma_2^2$	$(\frac{S_1^2/S_2^2}{F_{1-\alpha/2}(m-1, n-1)}, \frac{S_1^2/S_2^2}{F_{\alpha/2}(m-1, n-1)})$

**Příklad 10.** Při 600 hodech kostkou padla jednička pouze 45 krát. Rozhodněte, jestli je možné tvrdit, že jde o ideální kostku na hladině  $\alpha = 0,01$ . Vše zdůvodněte a svůj závěr explicitně formulujte.

**Příklad 11.** Do bedny ukládáme výrobky se střední hodnotou 3 kg a směrodatnou odchylkou 0,8 kg. Jaký maximální počet výrobků můžeme do bedny uložit, aby celková hmotnost s pravděpodobností 0,9738 nepřekročila jednu tunu?

Výsledek.  $n \approx 324$ .

**Příklad 12.** Odběratel provádí kontrolu jakosti námi dodaných výrobků namátkovou kontrolou testovaného rozměru u 21 náhodně vybraných výrobků. Dodávka bude přijata, pokud nebude výběrová směrodatná odchylka překračovat hodnotu 0,2 mm. Víme přitom, že naše stroje produkuje výrobky, u nichž má sledovaný rozměr normální rozdělení tvaru  $N(10 \text{ mm}; 0,0737 \text{ mm}^2)$ . S využitím statistických tabulek určete pravděpodobnost, s níž bude dodávka přijata. Jak se změnila odpověď, pokud odběratel kvůli nákladům na testy začne testovat pouze 4 výrobky? (V případě chybějících údajů v tabulce hodnoty, které máte k dispozici, lineárně interpolujte).

Výsledek. Při 21 testech je pravděpodobnost  $\chi_{20}^2(10, 9) = 0,05$ , při 4 testech  $\chi_3^2(1, 63) = 0,24$ .

**Příklad 13.** Ze základního souboru, z rozdělení  $N(\mu, \sigma^2)$ , kde  $\sigma^2 = 0,06$  jsme pořídili náhodný výběr s realizacemi 1,3; 1,8; 1,4; 1,2; 0,9; 1,5; 1,7. Určete oboustranný 95% interval spolehlivosti pro neznámou střední hodnotu.

Výsledek.  $1,22 \leq \mu \leq 1,58$ .

**Příklad 14.** Náhodná veličina  $X$  má normální rozdělení  $N(\mu, \sigma^2)$ , kde  $\mu, \sigma^2$  nejsou známy. V následující tabulce jsou uvedeny četnosti jednotlivých realizací této náhodné veličiny.

$x_i$	8	11	12	14	15	16	17	18	20	21
četnost	1	2	3	4	7	5	4	3	2	1

Vypočtete:

- výběrový průměr,
- výběrový rozptyl a výběrovou směrodatnou odchylku,
- 99% interval spolehlivosti pro střední hodnotu  $\mu$ .

Výsledek.  $13,954 \leq \mu \leq 16,671$

**Příklad 15.** Necht  $X_1, \dots, X_n$  je náhodný výběr z rozdělení  $N(\mu, 0,04)$ . Určete nejmenší počet měření, která je třeba provést, aby šířka 95% intervalu spolehlivosti pro  $\mu$  nepřesáhla 0,16.

Výsledek. 25

**Příklad 16.** Byla provedena čtyři navzájem nezávislá měření obsahu manganu u dvou vzorků oceli a byly získány výsledky:

1. vzorek	0,31%	0,30%	0,29%	0,32%
2. vzorek	0,59%	0,57%	0,58%	0,57%

Stanovte 95% interval spolehlivosti pro rozdíl středních hodnot  $\mu_1 - \mu_2$  za předpokladu, že jde o realizace náhodného výběru z normálního rozdělení s neznámými, ale shodnými rozptyly.

### 1. TESTOVÁNÍ HYPOTÉZ:

Testování hypotéz umožňuje na základě náhodného výběru s danou pravděpodobností ověřovat domněnky o rozdělení, z něhož pochází daný náhodný výběr.

**Hypotézou** budeme rozumět nějaké tvrzení o parametrech tohoto rozdělení.

$H_0$  ... nulová hypotéza (např.  $\theta = c$ , kde  $c$  je domněnka o hodnotě parametru  $\theta$ )

$H_1$  ... (oboustranná) alternativní hypotéza (obvykle negace nulové)

Testováním  $H_0$  oproti alternativní hypotéze rozumíme postup založený na náhodném výběru, s jehož pomocí platnost  $H_0$  zamítneme nebo nezamítneme (= připouštíme).

Chyba 1. druhu ...  $H_0$  platí a my ji zamítneme (závažnější)

Chyba 2. druhu ...  $H_0$  neplatí a my ji nezamítneme

Pravděpodobnost chyby 1. druhu se nazývá *hladina významnosti* ( $\alpha$ , obvykle  $\alpha = 0,05$ ), pravděpodobnost chyby 2. druhu se značí  $\beta$  a číslo  $1 - \beta$  se nazývá *síla testu*. Hypotézy budeme testovat pomocí příslušnosti do intervalu spolehlivosti – na základě realizace náhodného výběru sestojíme  $100(1 - \alpha)\%$  interval spolehlivosti pro neznámý parametr  $\theta$  a zjistíme, zda  $c$  patří do tohoto intervalu. Pokud ano, hypotézu  $H_0$  nezamítáme (v opačném případě zamítáme) na hladině významnosti  $\alpha$ .

**Příklad 17.** Z velkého souboru resistorů téhož typu bylo náhodně vybráno 16 kusů s výběrovým průměrem hodnot odporu 9,3 k $\Omega$ . Na hladině významnosti 0,05 testujte hypotézu, že výběr pochází z normálního rozdělení se střední hodnotou  $\mu = 10$  k $\Omega$ , za předpokladu, že:

- $\sigma^2 = 4$  k $\Omega$ ,
- $\sigma^2$  není známo a  $S^2 = 6,25$  k $\Omega$ .

Výsledek. a) nezamítáme, b) nezamítáme.

**Příklad 18.** Na dvou soustruzích se vyrábějí tytéž součástky, u nichž se měříme vnitřní průměr (předpokládá se normální rozdělení se stejnými rozptyly u obou soustruhů). Byl pořízen náhodný výběr rozsahu 16 z produkce prvního soustruhu a rozsahu 25 z produkce druhého soustruhu. Příslušné výběrové průměry jsou 37,5 mm, resp. 36,8 mm a výběrový rozptyly 1,21 mm<sup>2</sup>, resp. 1,44 mm<sup>2</sup>. Testujte hypotézu o rovnosti střední hodnoty kontrolovaných rozměrů v produkci obou strojů oproti oboustranné alternativě při  $\alpha = 0,1$ .

**Příklad 19.** Na šachový turnaj má být vybrán jeden zástupce ze dvou oddílových šachistů, a to ten, jehož výkon je stabilnější (má menší rozptyl). Procentuální úspěšnost z posledních turnajů je:

A	49,6	59,4	59,5	76,8	69,4	70,9	68,1	66,3
B	38,5	51,2	79,5	72,3	86,5			

Na hladině významnosti 0,05 testujte, zda je možno rozhodnout o tom, který z hráčů se má turnaje zúčastnit.