

# Popisná statistika

## základní soubor $X$ výběrový soubor

Naměřili jsme  $n$  hodnot

$$x_1, x_2, \dots, x_n,$$

počet prvků souboru je tzv. **rozsah** souboru. Pro lepší zpracování data uspořádáme:

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

a dostaneme **uspořádaný soubor hodnot**

## Míry polohy

**Průměr** (resp. výběrový, aritmetický průměr)

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

**p-kvantil** (výběrový p-kvantil)

$$\tilde{x}_p = \begin{cases} x_{([np]+1)} & np \neq [np] \\ \frac{1}{2}(x_{(np)} + x_{(np+1)}) & np = [np] \end{cases},$$

kde  $[a]$  značí celou část z  $a$  a  $0 < p < 1$ .

## Míry variability

**Rozptyl** (výběrový rozptyl)

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right)$$

**Kvartilové rozpětí**

$$r_Q = \tilde{x}_{0,75} - \tilde{x}_{0,25}$$

**Krabicový diagram** (box plot, box and whisker plot, vousatá krabice)

„Krabice“ je ohraničena hodnotami kvartilů a je zobrazen medián. „Vousky“ znázorňují hodnoty, které nejsou od jednotlivých kvartilů vzdálené o více jak 1,5 násobek  $R_Q$ . Jednotlivě jsou vyznačena pozorování, která jsou ve větší vzdálenosti.

1. Byly naměřeny hodnoty nějakého jevu:

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

Určete průměr, medián, kvartily, rozptyl, mezikvartilové rozpětí, hodnoty znázorníte pomocí krabicového diagramu a zakreslete výběrovou distribuční funkci.

## Náhodný výběr

Náhodným výběrem (rozsahu  $n$ ) nazýváme posloupnost  $n$  stochasticky nezávislých náhodných veličin  $X_1, X_2, \dots, X_n$ , které mají stejné rozložení, tedy  $X_i \sim F(x_i)$ ,  $i = 1, 2, \dots, n$ .

Pozn.: Prakticky se s náhodným výběrem setkáváme při nezávislém vícenásobném opakování téhož pokusu.

**Statistika:** Náhodná veličina, která vznikne transformací náhodného výběru, se nazývá statistika.

Významné statistiky:

- Výběrový průměr

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

- Výběrový rozptyl

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n X_i^2 - n\bar{X}^2 \right)$$

- Výběrová směrodatná odchylka

$$S = \sqrt{S^2}$$

- Výběrová kovariance

$$S_{12} = \frac{1}{n-1} \sum_{i=1}^n (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2)$$

2. Odvoďte pravděpodobnostní funkci náhodného výběru z alternativního rozložení  $A(\theta)$ .  
[ $\pi(\mathbf{x}) = \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n-\sum_{i=1}^n x_i}$  pro  $x_i = 0, 1$ ,  $i = 1, \dots, n$  a  $\pi(\mathbf{x}) = 0$  jinak]
3. Odvoďte hustotu náhodného výběru z normálního rozložení  $N(\mu, \sigma^2)$ . [  $N_n(\mu \mathbf{1}, \sigma^2 \mathbb{I})$  ]
4. Nechť  $X_1, X_2, \dots, X_n$  je náhodný výběr z rozložení, které má střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ . Vypočítejte střední hodnotu a rozptyl výběrového průměru  $\bar{X}$  a střední hodnotu výběrového rozptylu  $S^2$ .  
[  $E(\bar{X}) = \mu$ ,  $D(\bar{X}) = \frac{\sigma^2}{n}$ ,  $E(S^2) = \sigma^2$  ]
5. Odvoďte rozložení výběrového průměru  $\bar{X}$ , jestliže náhodný výběr pochází
  - (a) z normálního rozložení  $N(\mu, \sigma^2)$ , [  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$  ]
  - (b) z alternativního rozložení  $A(\theta)$ . [  $\pi_*(\bar{x}) = \binom{n}{n\bar{x}} \theta^{n\bar{x}} (1-\theta)^{n-n\bar{x}}$  pro  $\bar{x} = 0, 1/n, 2/n, \dots, 1$  a  $\pi_*(\bar{x}) = 0$  jinak ]
6. Nechť  $(X_{11}, X_{21})', \dots, (X_{1n}, X_{2n})'$  je náhodný výběr z rozložení s vektorem středních hodnot  $(\mu_1, \mu_2)'$  a kovariancí  $C(X_{1i}, X_{2i}) = \kappa$ ,  $i = 1, \dots, n$ . Vypočítejte střední hodnotu výběrové kovariance  $S_{12}$ . [  $S_{12} = \kappa$  ]
7. Předpokládejme, že velký ročník na vysoké škole má výsledky ze statistiky normálně rozloženy kolem střední hodnoty 72 bodů se směrodatnou odchylkou 9 bodů. Určete pravděpodobnost, že
  - (a) náhodně vybraný student bude mít výsledek nad 80 bodů [0,18673]
  - (b) průměr výsledků náhodného výběru 10 studentů bude větší než 80 bodů. [0,00248]

8. Necht  $X_1, X_2, \dots, X_n$  je náhodný výběr z rozložení  $N(10, 4)$ . Jaká je pravděpodobnost, že výběrový průměr nabude hodnoty nejvýše 9.5? Sledujte vliv rozsahu výběru na tuto pravděpodobnost.

$$[\Phi(-0, 25\sqrt{n})]$$