

## 7. přednáška – POPISNÁ STATISTIKA

Explorační (popisná) statistika bývá prvním krokem k odhalení informací skrytých ve velkém množství proměnných a jejich variant.

### **STATISTICKÉ CHARAKTERISTIKY NUMERICKÝCH PROMĚNNÝCH**

#### **Třídění dat**

Nejčastěji postupujeme tak, že data uspořádáme podle velikosti a stanovíme intervaly, které odpovídají jednotlivým třídám. Mluvíme pak o intervalovém třídění.

#### **Četnosti**

Absolutní četnost -  $f_i$ ;

Relativní četnost -  $\varphi_i = \frac{f_i}{n}$ ;

Kumulativní četnost -  $F_i = \sum_{k=1, \dots, i} f_k$ ;

Relativní kumulativní četnost -  $\Phi_i = \frac{F_i}{n}$ ;

*Příklad:* Ze 7 možných výsledků jsme dostali datový soubor o 14 datech: 2,1,3,2,5,2,7,1,4,5,4,2,1,5. Určete četnosti.

#### **Grafická znázornění**

**Histogram** - graf kdy na vodorovnou osu znázorníme třídy a na svislou osu četnosti či relativní četnosti.

**Kruhový (výsečový) diagram** - je znázornění pomocí výsečí kruhu, kde každé třídě odpovídá jedna výseč. Velikosti obsahů výsečí odpovídají četnostem třídy.

**Stem-and-Leaf diagram** - je uspořádání dat do tabulky

**Krabicový graf** - znázorňuje význačné a extrémní hodnoty souboru

*Příklad:* pokračování, graficky znázorněte data

## Charakteristiky míry

Průměr (aritmetický)

- datového souboru je definován  $\bar{x} = \frac{1}{n} \sum_{k=1}^n x_k$
- soubor s četnostmi:  $\bar{x} = \frac{1}{n} \sum_{i=1}^m z_i \cdot f_i$ , kde  $z_i$  je zástupce i-té třídy

Medián  $x_{0,5}$  - je ta hodnota, která rozděluje soubor na dvě části o stejném počtu prvků

Modus -  $Mo(x)$  je ta hodnota, která má největší absolutní četnost

Pokračování *příklad*: určete průměr, medián a modus

## Charakteristiky variability

Následující statistické charakteristiky nám umožňují popis variability (rozptýlenosti) výběrového souboru, neboli popis rozptylu jednotlivých hodnot kolem středu proměnné – nazýváme je tedy mírami variability.

Variační rozpětí  $R$  - rozdíl mezi největší a nejmenší hodnotou kvantitativního znaku

$$R = x_{\max} - x_{\min}$$

Interkvartilové rozpětí  $IQR$  – vzdálenost mezi dolním a horním kvantilem

$$IQR = x_{0,75} - x_{0,25}$$

Výběrový rozptyl  $s^2$  - nejrozšířenější míra variability výběrového souboru

$$s^2 = \frac{1}{n-1} \sum_{k=1}^n (x_k - \bar{x})^2$$

Pokud jsou data zadána jako soubor s četnostmi, využijeme vzorce:

$$s^2 = \frac{1}{n} \sum_{k=1}^n n_k (x_k - \bar{x})^2$$

Výběrová směrodatná odchylka  $s$  - definována jako kladná odmocnina výběrového rozptylu

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

Pokračování *příklad*: určete charakteristiky variability

Variační koeficient  $V_x$  - vyjadřuje relativní míru variability proměnné  $x$ . Podle níže uvedeného vztahu jej lze stanovit pouze pro proměnné, které nabývají výhradně kladných hodnot. Variační koeficient je bezrozměrný. Uvádíme-li jej v [%], hodnotu získanou z definičního vzorce vynásobíme 100%.

$$V_x = \frac{s}{\bar{x}}$$

*Příklad*: V levé skupině máme tři čísla : 7; 8; 9. V pravé skupině máme čísla 1; 10, 13. Určete variační koeficient pro obě skupiny.

Koeficient šikmosti - charakteristiky šikmosti udávají, jsou-li hodnoty kolem zvoleného středu rozloženy souměrně nebo je-li rozdělení hodnot zešikmeno na jednu stranu

$$A = \frac{1}{n} \sum_{k=1}^n \frac{(x_k - \bar{x})^3}{s^3}$$

Koeficient špičatosti - charakteristiky špičatosti udávají, jaký průběh má rozdělení hodnot kolem zvoleného středu (rozdělení).

$$e = \frac{1}{n} \sum_{k=1}^n \frac{(x_k - \bar{x})^4}{s^4}$$