

# Základy popisné statistiky

## 1. Základní pojmy

**Statistická jednotka** – každý prvek jehož vlastnosti zkoumáme (člověk, věc, instituce, ...)

**Statistický soubor** – obsahuje všechny jednotky, které zkoumáme.

**Rozsah souboru** – počet prvků souboru

**Statistický znak** – vlastnost statistických jednotek, kterou zkoumáme. Rozlišujeme dva základní typy znaků:

- ☞ kvantitativní (číselný), spojitý nebo diskrétní – rozměr výrobku, počet vyrobených kusů, počet výskytů vztekliny, ...
- ☞ kvalitativní (slovní) – používaný prací prášek, oblíbený politik, ...

### Četnosti

$x$  – statistický znak

$x_1, x_2, x_i, \dots, x_n$  – hodnoty statistického znaku

$n$  – rozsah souboru

$n_i$  – absolutní četnost hodnot znaku  $x$ , udává, kolikrát se v souboru vyskytuje hodnota znaku  $x_i$

$p_i = \frac{n_i}{n}$  – relativní četnost hodnot znaku  $x_i$ , v procentech  $\frac{n_i}{n} \cdot 100$

Platí:

- 1) součet absolutních četností je roven rozsahu souboru  $n$
- 2) součet relativních četností je roven 1

### Příklad

- 1) Při zjišťování počtu dětí ve dvaceti domácnostech jsme dostali výsledky: 0, 0, 2, 2, 1, 1, 1, 1, 1, 0, 0, 0, 3, 2, 1, 1, 2, 3, 2, 1. Vytvořte tabulku rozdělení absolutních i relativních četností a vyjádřete také zastoupení jednotlivých hodnot v procentech.

$x_i$	$n_i$	$p_i$	$p_i$ v %
0	5	0,25	25
1	8	0,40	40
2	5	0,25	25
3	2	0,10	10
<b>součet</b>	<b>20</b>	<b>1</b>	<b>100</b>

### Intervalové rozdělení četností

**Intervalové rozdělení četností** – pro spojité znaky nebo pro diskrétní s velkým množstvím hodnot. Blízké hodnoty se sdružují do intervalů (tříd, skupin). **Hodnoty, které patří do stejného intervalu, považujeme za rovnocenné a nahrazuje je střed intervalu.**

intervaly výšky v cm	četnosti $n_i$
153 – 157	7
158 – 162	20
163 – 167	35
168 – 172	49
173 – 177	84
178 – 182	60
183 – 187	27
188 – 192	14
193 – 197	4

## 2. Statistické charakteristiky polohy

Každá charakteristika polohy je číslo, kolem něhož jednotlivé hodnoty znaku kolísají.

### Aritmetický průměr $\bar{x}$

Každá hodnota znaku je součtem dvou složek:

- ☞ charakteristická pro celý soubor
- ☞ individuální odchylka, má náhodný charakter

Výpočet průměru charakteristická složka vynikne, protože individuální odchylky jsou kladné i záporné, a proto se v součtu ruší.

### Výpočet aritmetického průměru $\bar{x}$

#### Prostý aritmetický průměr

Máme-li k dispozici jednotlivé hodnoty.

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$$

#### Vážený aritmetický průměr s použitím absolutních četností

Máme-li k dispozici absolutní četnosti.

$$\bar{x} = \frac{x_1 n_1 + x_2 n_2 + \dots + x_k n_k}{n} = \frac{1}{n} \cdot \sum_{i=1}^k x_i \cdot n_i$$

#### Vážený aritmetický průměr s použitím relativních četností

Máme-li k dispozici relativní četnosti.

$$\bar{x} = x_1 p_1 + x_2 p_2 + \dots + x_k p_k = \sum_{i=1}^k x_i \cdot p_i$$

### Příklad

Data: 0, 0, 2, 2, 1, 1, 1, 1, 1, 0, 0, 0, 3, 2, 1, 1, 2, 3, 2, 1

*Prostý aritmetický průměr*

$$\bar{x} = \frac{0+0+2+2+1+\dots+3+2+1}{20} = 1,2$$

*Vážený aritmetický průměr s použitím absolutních četností*

$x_i$	$n_i$	$n_i \cdot x_i$
0	5	0
1	8	8
2	5	10
3	2	6
<b>součet</b>	<b>20</b>	<b>24</b>

$$\bar{x} = \frac{0 \cdot 5 + 1 \cdot 8 + 2 \cdot 5 + 3 \cdot 2}{20} = \frac{24}{20} = 1,2$$

*Vážený aritmetický průměr s použitím relativních četností*

$x_i$	$n_i$	$p_i$	$x_i \cdot p_i$
0	5	0,25	0
1	8	0,4	0,4
2	5	0,25	0,5
3	2	0,1	0,3
<b>součet</b>	<b>20</b>	<b>1</b>	<b>1,2</b>

$$\bar{x} = 0 \cdot 0,25 + 1 \cdot 0,4 + 2 \cdot 0,25 + 3 \cdot 0,1 = 1,2$$

**Všechny vzorce samozřejmě vedou ke stejnému výsledku, který vzorec použijeme, záleží na tom, jaké údaje máme k dispozici**

**Použití aritmetického průměru je nejvhodnější v případech, kdy hodnoty znaku jsou rovnoměrně rozloženy okolo aritmetického průměru**

## *Medián*

Medián je definován jako prostřední hodnota výběru, hodnoty **musí být uspořádány podle velikosti**:

- ☞ rozsah souboru  $n$  je liché číslo – medián je roven hodnotě prostředního znaku
- ☞ rozsah souboru  $n$  je sudé číslo – medián je roven aritmetickému průměru dvou prostředních hodnot.

Polovina hodnot výběru je tedy menší nebo rovna mediánu, polovina hodnot je větší nebo rovna mediánu.

**Medián se používá především u souborů, kde hodnoty znaku u některých jednotek extrémně vybočují z řady ostatních jednotek.**

## *Modus*

Je to nejčastěji se vyskytující hodnota (hodnota s největší absolutní četností).