

1 Popisná statistika

1.1 Úvod

V této kapitole se omezíme na popis jednorozměrných statistických souborů. Budeme předpokládat, že jsou k dispozici reálná čísla x_1, \dots, x_n . To mohou být výsledky nějakých měření nebo pokusů. Dost často se stává, že číslo n je velké. Prostý výpis hodnot x_1, \dots, x_n je pak zcela nepřehledný. Je třeba proto informaci o tomto souboru zkoncentrovat do menšího počtu ukazatelů, které se dají snadno interpretovat.

Z terminologického hlediska si povšimněme, že *soubor hodnot* x_1, \dots, x_n není totéž jako *množina hodnot* $\{x_1, \dots, x_n\}$. Důvodem je to, že v souboru se mohou některé hodnoty opakovat. To odpovídá termínu soubor užívanému při práci s počítači.

Někdy je nutné čísla x_1, \dots, x_n uspořádat do neklesající posloupnosti

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

To tedy znamená, že speciálně

$$x_{(1)} = \min_i x_i, \quad x_{(n)} = \max_i x_i.$$

V této kapitole se nejdřív zmíníme o případě, kdy skutečně je možné s celým souborem x_1, \dots, x_n pracovat najednou. To je dnes už poměrně časté díky velké paměti počítačů. I přesto se někdy z různých důvodů stane, že je nutné pracovat s daty shrnutými do nějaké tabulky. O práci s tabulkami se zmíníme v závěru této kapitoly.

1.2 Míry polohy

Snad nejznámější mírou polohy je *aritmetický průměr*

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

Stručně mu budeme říkat jen *průměr*. Dnes je sice proti jeho používání v některých situacích vznášena řada námitek (např. jeho citlivost na hrubé chyby — i jeden jediný údaj x_i může výsledek zcela zkreslit), ale už vzhledem k jeho úzké souvislosti se *souhrnem* $\sum x_i = n\bar{x}$ stále zůstává důležitým ukazatelem. Není pochyb o tom, že třebas souhrn úspor obyvatelstva přináší podstatnou informaci o ekonomické situaci státu.

Velmi jednoduchou, ale neustále používanou vlastností průměru je

$$\sum (x_i - \bar{x}) = 0. \quad (1.1)$$

Slovy vyjádřeno to znamená, že součet odchylek od aritmetického průměru je roven nule. Důkaz vzorce (1.1) je triviální. Uvedme další jednoduchou vlastnost průměru. Nechť a, b jsou daná čísla a položíme $y_i = a + bx_i$, $i = 1, \dots, n$. Pak

$$\bar{y} = a + b\bar{x}. \quad (1.2)$$

Dříve se *lineárních transformací* používalo hlavně ke zjednodušení numerického výpočtu průměru.

Jsou-li všechna čísla x_1, \dots, x_n kladná, pak se definuje *geometrický průměr* vzorcem

$$\bar{x}_G = \sqrt[n]{x_1 \dots x_n}.$$

Příklad 1.1 Naznačme jedno použití geometrického průměru. Nechť x_i je počet výrobků prodaných v i -tém časovém období (např. počet automobilů prodaných v i -tém roce), $i = 0, \dots, n$. Vývoj prodeje se dá charakterizovat pomocí tzv. *řetězových indexů*

$$i_1 = \frac{x_1}{x_0}, \dots, i_n = \frac{x_n}{x_{n-1}}.$$

Pomocí nich lze množství x_n vyjádřit jako

$$x_n = x_0 i_1 \dots i_n. \quad (1.3)$$

Soubor indexů i_1, \dots, i_n je výhodné charakterizovat jejich geometrickým průměrem

$$\bar{i}_G = \sqrt[n]{i_1 \dots i_n}.$$

Ten totiž může zastoupit každý z indexů i_1, \dots, i_n ve vzorci (1.3) v tom smyslu, že

$$x_n = x_0 (\bar{i}_G)^n. \quad \diamond$$

Věta 1.2 *Nechť x_1, \dots, x_n jsou kladná čísla. Pak platí*

$$\bar{x}_G \leq \bar{x} \quad (1.4)$$

a rovnosti je dosaženo právě tehdy, platí-li $x_1 = \dots = x_n$.

Důkaz. Položme $f(x) = \ln x$ pro $x > 0$. Podle Taylorova vzorce pro libovolné pevné $\mu > 0$ platí

$$f(x) = f(\mu) + (x - \mu)f'(\mu) + \frac{1}{2}(x - \mu)^2 f''(\theta), \quad (1.5)$$

kde bod θ leží mezi x a μ . Protože $f''(\theta) = -\theta^{-2} < 0$ pro každé $\theta > 0$, dostáváme

$$f(x) \leq f(\mu) + (x - \mu)f'(\mu). \quad (1.6)$$

Je jasné, že rovnost v (1.6) platí právě tehdy, je-li $x = \mu$. Proto pro každé x_i máme

$$\ln x_i \leq \ln \mu + (x_i - \mu)f'(\mu), \quad i = 1, \dots, n. \quad (1.7)$$

Sečtením těchto nerovností se dostane

$$\sum \ln x_i \leq n \ln \mu + f'(\mu) \sum (x_i - \mu).$$

Položme $\mu = \bar{x}$. Užitím (1.1) se dostane

$$\sum \ln x_i \leq n \ln \bar{x}, \quad (1.8)$$

což je ekvivalentní s (1.4). Přitom rovnost v (1.8) platí právě tehdy, platí-li rovnost v (1.6) pro každé i , tj. když $x_1 = \mu, \dots, x_n = \mu$. Tedy rovnost v (1.8) nastane, právě když si jsou všechna čísla x_1, \dots, x_n rovna. \square

Jsou-li všechna čísla x_1, \dots, x_n kladná, definuje se *harmonický průměr* \bar{x}_H vztahem

$$\bar{x}_H = \frac{n}{x_1^{-1} + \dots + x_n^{-1}}.$$

Věta 1.3 *Jsou-li všechna čísla x_1, \dots, x_n kladná, pak platí*

$$\bar{x}_H \leq \bar{x}_G. \quad (1.9)$$

Přitom rovnosti v (1.9) je dosaženo právě tehdy, platí-li $x_1 = \dots = x_n$.

Důkaz. Užitím věty 1.2 dostaneme

$$\frac{1}{\bar{x}_H} = \frac{1}{n} \sum x_i^{-1} \geq \sqrt[n]{x_1^{-1} \dots x_n^{-1}},$$

což je ekvivalentní s (1.9). Podmínka pro rovnost se rovněž přenáší z věty 1.2. \square

Příklad 1.4 Význam harmonického průměru může osvětlit následující úloha. Auto jede do kopce rychlostí v_1 a pak po stejné trati zpět z kopce rychlostí v_2 . Jaká je jeho průměrná rychlost?

Označme d délku tratě do kopce, t_1 dobu jízdy do kopce a t_2 dobu jízdy z kopce. Máme $t_1 = d/v_1$, $t_2 = d/v_2$. Celková dráha do kopce i zpět je $2d$, celkový čas potřebný k jejímu projetí je $t = t_1 + t_2$. Proto je průměrná rychlost

$$v = \frac{2d}{t} = \frac{2}{v_1^{-1} + v_2^{-1}} \quad (1.10)$$

a je to tedy harmonický průměr rychlostí v_1 a v_2 . \diamond

Někdy se definuje *kvadratický průměr* \bar{x}_K vztahem

$$\bar{x}_K = \sqrt{\frac{x_1^2 + \dots + x_n^2}{n}}.$$

Věta 1.5 Pro libovolná reálná čísla x_1, \dots, x_n platí

$$\bar{x} \leq \bar{x}_K. \quad (1.11)$$

Přitom rovnost nastává tehdy a jen tehdy, je-li $x_1 = \dots = x_n$.

Důkaz. Položme $f(x) = x^2$. Podle Taylorova vzorce platí pro každé pevně dané reálné μ vzorec (1.5), kde nyní $f''(\theta) = 2$. Máme tedy

$$f(x) \geq f(\mu) + (x - \mu)f'(\mu),$$

tj.

$$x^2 \geq \mu^2 + (x - \mu)f'(\mu).$$

Přitom zde rovnost platí tehdy a jen tehdy, je-li $x = \mu$. Tudíž

$$x_i^2 \geq \mu^2 + (x_i - \mu)f'(\mu), \quad i = 1, \dots, n$$

a sečtením dostaneme

$$\sum x_i^2 \geq n\mu^2 + f'(\mu) \sum (x_i - \mu). \quad (1.12)$$

Zvolíme-li $\mu = \bar{x}$, pak užitím (1.1) máme

$$\sum x_i^2 \geq n\bar{x}^2, \quad (1.13)$$

což je ekvivalentní s (1.11). Rovnost v (1.13) platí právě tehdy, platí-li v (1.12) rovnost pro každé $i = 1, \dots, n$. To znamená, že si musí být všechna x_i rovna. \square

Nechť všechna čísla x_1, \dots, x_n jsou kladná. Snadno se lze přesvědčit, že platí

$$x_{(1)} \leq \bar{x}_H, \quad \bar{x}_K \leq x_{(n)}.$$

Proto z dosavadních výsledků vyplývá, že

$$x_{(1)} \leq \bar{x}_H \leq \bar{x}_G \leq \bar{x} \leq \bar{x}_K \leq x_{(n)}. \quad (1.14)$$

V případě $x_1 = \dots = x_n$ platí všude v (1.14) rovnost. Nejsou-li si všechna x_i rovna, pak v (1.14) jsou všude ostré nerovnosti.

Zhruba se dá říci, že \bar{x} slouží k náhradě individuálních x_i při sčítání, neboť

$$x_1 + \dots + x_n = \bar{x} + \dots + \bar{x}.$$

Obdobně \bar{x}_G nahrazuje jednotlivé hodnoty x_i při násobení, \bar{x}_H při počítání s převrácenými hodnotami a \bar{x}_K při sčítání čtverců v tom smyslu, že

$$\begin{aligned} x_1 \dots x_n &= \bar{x}_G \dots \bar{x}_G, \\ \frac{1}{x_1} + \dots + \frac{1}{x_n} &= \frac{1}{\bar{x}_H} + \dots + \frac{1}{\bar{x}_H}, \\ x_1^2 + \dots + x_n^2 &= \bar{x}_K^2 + \dots + \bar{x}_K^2. \end{aligned}$$

Je evidentní, že by se daly definovat jiné typy průměrů, které by nahrazovaly původní hodnoty při dalších operacích. Zde rozebereme jednu takovou možnost. Zřejmě platí

$$\bar{x}_H = \left(\frac{1}{n} \sum x_i^{-1} \right)^{-1}, \quad \bar{x} = \frac{1}{n} \sum x_i, \quad \bar{x}_K = \left(\frac{1}{n} \sum x_i^2 \right)^{\frac{1}{2}}.$$

Zavedme tedy v případě kladných x_1, \dots, x_n průměr stupně α vzorcem

$$\bar{x}_\alpha = \left(\frac{1}{n} \sum x_i^\alpha \right)^{1/\alpha}, \quad \alpha \neq 0. \quad (1.15)$$

Vidíme, že

$$\bar{x}_{-1} = \bar{x}_H, \quad \bar{x}_1 = \bar{x}, \quad \bar{x}_2 = \bar{x}_K.$$

Ve vzorci (1.15) bylo nutné vyloučit hodnotu $\alpha = 0$. Nyní vyšetříme limitu \bar{x}_α pro $\alpha \rightarrow 0$.

Věta 1.6 *Nechť x_1, \dots, x_n jsou vesměs kladná čísla. Pak platí*

$$\lim_{\alpha \rightarrow 0} \bar{x}_\alpha = \bar{x}_G.$$