

MATEMATICKÁ STATISTIKA

Dana Černá

<http://www.fp.tul.cz/kmd/>

Katedra matematiky a didaktiky matematiky

Technická univerzita v Liberci

Matematická statistika

Matematická statistika se zabývá matematickým zpracováním dat a rozbořem získaných výsledků.

Data chápeme jako realizace náhodných veličin. **Statistický soubor** je množina všech sledovaných objektů, jednotlivé objekty nazýváme **statistické jednotky**. Počet všech prvků souboru se nazývá **rozsah souboru**.

Rozlišujeme statistický soubor

- **základní** - množina všech objektů se sledovanou vlastností
- **výběrový** - je podmnožinou základního souboru, obsahuje objekty, ke kterým známe hodnoty sledovaných vlastností

Sledovanou vlastnost nazýváme **statistický znak**. Rozlišujeme statistický znak

- **kvantitativní** - je vyjádřen číslem
- **kvalitativní** - není vyjádřen číslem

(Absolutní) četnost znaku je definována jako počet statistických jednotek se stejnou hodnotou znaku. Označme absolutní četnost hodnoty ξ_i symbolem n_i , platí $\sum_{i=1}^m n_i = n$, kde n je rozsah souboru a m je počet všech hodnot.

Relativní četnost hodnoty ξ_i je definována vztahem $v_i = \frac{n_i}{n}$. Platí $\sum_{i=1}^m v_i = 1$.

Pokud statistický znak nabývá příliš mnoha hodnot, rozdělíme hodnoty do intervalů a potom používáme **intervalové rozdělení četnosti**. Intervaly mají zpravidla stejnou délku. Jejich počet určíme pomocí **Sturgesova vzorce**

$$k = 1 + 3,3 \log_{10} n,$$

kde k značí počet intervalů a n označuje rozsah souboru. Daný interval potom zpravidla reprezentuje jeho střed.

Charakteristiky statistického souboru

Budeme rozlišovat

- charakteristiky polohy,
- charakteristiky variability,
- charakteristiky statistické závislosti.

Značení:

Data budeme označovat x_1, x_2, \dots, x_n .

Hodnoty znaku x budeme značit $\xi_1, \xi_2, \dots, \xi_m$ a jejich četnosti označíme n_1, n_2, \dots, n_m .

Vzestupně uspořádaná data označíme $x_{(1)}, x_{(2)}, \dots, x_{(n)}$.

Charakteristiky polohy

1. Aritmetický průměr

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \text{ nebo } \bar{x} = \frac{1}{n} \sum_{i=1}^n n_i \xi_i.$$

2. Harmonický průměr

$$\bar{x}_H = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}} \text{ nebo } \bar{x}_H = \frac{n}{\sum_{i=1}^n \frac{n_i}{\xi_i}}.$$

Například průměrná rychlost je harmonickým průměrem rychlostí na jednotlivých úsecích.

3. Geometrický průměr

$$\bar{x}_G = \sqrt[n]{x_1 x_2 \dots x_n} = \sqrt[n]{\xi_1^{n_1} \xi_2^{n_2} \dots \xi_m^{n_m}}.$$

Používá se k výpočtu průměrné inflace, průměrného úroku, průměrného růstu výroby, HDP apod.

4. **Medián** je prostřední hodnota mezi uspořádanými daty.

$Med = x_{(\frac{n+1}{2})}$, pokud n je liché.

$Med = \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}}{2}$, pokud n je sudé.

5. **Modus** je hodnota s největší četností.

6. **Dolní kvartil**

$x_{0,25} = \frac{x_{([\frac{n}{4}]}) + x_{([\frac{n}{4}]+1)}}{2}$, kde $[\]$ označuje celou část.

7. **Horní kvartil**

$x_{0,75} = \frac{x_{([\frac{3n}{4}]}) + x_{([\frac{3n}{4}]+1)}}{2}$

Charakteristiky variability

1. Rozsah souboru

$$R = x_{(n)} - x_{(1)}.$$

2. Mezikvartilové rozpětí

$$Q = x_{0,75} - x_{0,25}.$$

3. Výběrový rozptyl

$$\begin{aligned} s_1^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \sum_{i=1}^n x_i^2 - \frac{n}{n-1} \bar{x}^2 \\ &= \frac{1}{n-1} \sum_{i=1}^m n_i (\xi_i - \bar{x})^2 = \frac{1}{n-1} \sum_{i=1}^m n_i \xi_i^2 - \frac{n}{n-1} \bar{x}^2 \end{aligned}$$

$$\begin{aligned}s_2^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \\ &= \frac{1}{n} \sum_{i=1}^m n_i (\xi_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^m n_i \xi_i^2 - \bar{x}^2\end{aligned}$$

4. Výběrová směrodatná odchylka

$$s_1 = \sqrt{s_1^2}, \text{ nebo } s_2 = \sqrt{s_2^2}$$

5. Variační koeficient

$$v = \frac{s_1}{\bar{x}}, \text{ nebo } v = \frac{s_2}{\bar{x}}$$

Charakteristiky statistické závislosti

U každého objektu budeme sledovat znak x a znak y . Potom jsou data dána ve dvojicích, dvojice (x_i, y_i) určuje zjištěné hodnoty pro i -tý objekt, nebo jsou data zadána pomocí hodnot (ξ_i, η_i) a jejich četností n_i .

Výběrová kovariance

$$\begin{aligned} \text{cov}(x, y) &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y} \\ &= \frac{1}{n} \sum_{i=1}^m n_i (\xi_i - \bar{x})(\eta_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^m n_i \xi_i \eta_i - \bar{x} \bar{y} \end{aligned}$$

Výběrový korelační koeficient

$$\rho(x, y) = \frac{\text{cov}(x, y)}{s_x s_y},$$

kde

$$s_x = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{\frac{1}{n} \sum_{i=1}^m n_i (\xi_i - \bar{x})^2},$$
$$s_y = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} = \sqrt{\frac{1}{n} \sum_{i=1}^m n_i (\eta_i - \bar{y})^2}$$

O znacích x a y řekneme, že jsou **nezávislé**, jestliže náhodné veličiny reprezentující tyto znaky jsou nezávislé.

Jestliže jsou znaky nezávislé, potom $\rho(x, y) \approx 0$.

Jestliže $\rho(x, y)$ není přibližně nulový, potom znaky x a y nejsou nezávislé.

Jestliže $|\rho(x, y)| \approx 1$, potom y závisí lineárně na x , tj. existují konstanty a a b takové, že $y = ax + b$.

Bodový odhad

Jestliže X_1, X_2, \dots, X_n jsou nezávislé stejně rozdělené náhodné veličiny, řekneme, že X_1, X_2, \dots, X_n je **náhodný výběr**. Realizace těchto náhodných veličin x_1, x_2, \dots, x_n nazýváme **realizovaný náhodný výběr**.

Předpokládejme, že X_1, X_2, \dots, X_n je náhodný výběr z rozdělení, které závisí na parametru $\theta \in M$.

Libovolné $\hat{\theta} \in M$ se nazývá **bodový odhad** parametru θ .

$\hat{\theta} \in M$ se **nestranný odhad** parametru θ , jestliže $E\hat{\theta} = \theta$.

VĚTA: Jestliže X_1, X_2, \dots, X_n je náhodný výběr a $EX_i = \mu \in \mathbb{R}$,
potom $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ je nestranný odhad parametru μ .

Důkaz: $E\bar{X} = E\frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} \sum_{i=1}^n EX_i = \frac{1}{n} \sum_{i=1}^n \mu = \mu$.

VĚTA: Jestliže X_1, X_2, \dots, X_n je náhodný výběr a $\text{var } X_i = \sigma^2 \in \mathbb{R}$,
potom $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ je nestranný odhad parametru σ^2 .

Maximálně věrohodný odhad

Předpokládejme, že $\mathbf{X} = (X_1, X_2, \dots, X_n)$ je náhodný výběr z rozdělení, které závisí na parametru $\theta \in M$, $\mathbf{x} = (x_1, x_2, \dots, x_n)$ je realizace tohoto náhodného výběru.

Definujme **věrohodnostní funkci** předpisem

$$L_{\theta}(\mathbf{x}) = P_{\theta}(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n),$$

pokud X_i mají diskrétní rozdělení pravděpodobnosti P_{θ} , a předpisem

$$L_{\theta}(\mathbf{x}) = \prod_{i=1}^n f_{\theta}(x_i),$$

kde f_{θ} je hustota X_i , pokud X_i mají spojité rozdělení pravděpodobnosti s parametrem θ .

Maximálně věrohodný odhad parametru θ je definován:

$$\hat{\theta} = \operatorname{argmax}_{\theta \in M} L_{\theta}(\mathbf{x}) = \operatorname{argmax}_{\theta \in M} \ln L_{\theta}(\mathbf{x}).$$