

Výběrové charakteristiky

průměr

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

$$\bar{x}_G = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n} \quad \text{geometrický}$$

$$\bar{x}_H = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}} \quad \text{harmonický}$$

100p% kvantil - hodnota x_p dělí setříděný soubor na 2 části, poměr dělení je $p : (1 - p)$, $p \in \langle 0, 1 \rangle$

$x_{0.25}$ dolní kvartil

$x_{0.5} = \tilde{x}$ medián, prostřední hodnota

$x_{0.75}$ horní kvartil

modus

\hat{x} nejčastěji se vyskytující hodnota proměnné

variální rozpětí

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

interkvartilové rozpětí

$$IQR = x_{0.75} - x_{0.25}$$

výběrový rozptyl

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

výběrová směrodatná odchylka

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

variální koeficient

$$V = \frac{s}{\bar{x}} \quad \text{vyjadřuje se v procentech (\cdot 100\%)}$$

výběrová střední chyba průměru

$$s_X = \frac{s}{\sqrt{n}}$$

výběrová šikmost

$$a = \frac{n}{(n-1)(n-2)} \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{s^3}$$

výběrová špičatost

$$e = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{s^4} - 3 \frac{(n-1)^2}{(n-2)(n-3)}$$

Identifikace odlehlých pozorování

z-souřadnice

$$z_i = \frac{x_i - \bar{x}}{s} \quad |z_i| > 3 \Rightarrow x_i \text{ je odlehlá}$$

mediánová souřadnice

$$m_i = \frac{x_i - x_{0.5}}{1.483 \text{ MAD}} \quad |m_i| > 3 \Rightarrow x_i \text{ je odlehlá}$$

MAD ... medián absolutních odchylek od mediánu

vnitřní hradby

$$[(x_i < x_{0.25} - 1.5 \text{ IQR}) \vee (x_i > x_{0.75} + 1.5 \text{ IQR})] \Rightarrow x_i \text{ je odlehlá}$$

vnější hradby

$$[(x_i < x_{0.25} - 3 \text{ IQR}) \vee (x_i > x_{0.75} + 3 \text{ IQR})] \Rightarrow x_i \text{ je extrémní}$$

Intervalové odhady

střední hodnota

$$P\left(\bar{x} - \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}} \leq \mu \leq \bar{x} + \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}}\right) = 1 - \alpha \quad \text{normalita nebo } n > 30, \text{ známe } \sigma^2$$

$$\text{Excel: } u_{1-\frac{\alpha}{2}} = \text{NORM.S.INV}(1 - \frac{\alpha}{2})$$

$$P\left(\bar{x} - \frac{s}{\sqrt{n}} t_{1-\frac{\alpha}{2}; n-1} \leq \mu \leq \bar{x} + \frac{s}{\sqrt{n}} t_{1-\frac{\alpha}{2}; n-1}\right) = 1 - \alpha \quad \text{normalita, neznáme } \sigma^2$$

$$\text{Excel: } t_{1-\frac{\alpha}{2}; n-1} = \text{T.INV}(1 - \frac{\alpha}{2}; n-1)$$

rozptyl

$$P\left(\frac{(n-1)s^2}{\chi_{1-\frac{\alpha}{2}; n-1}^2} \leq \sigma^2 \leq \frac{(n-1)s^2}{\chi_{\frac{\alpha}{2}; n-1}^2}\right) = 1 - \alpha \quad \text{normalita}$$

$$\text{Excel: } \chi_{1-\frac{\alpha}{2}; n-1}^2 = \text{CHISQ.INV}(1 - \frac{\alpha}{2}; n-1)$$

parametr binomického rozdělení

$$P\left(p - u_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \leq \pi \leq p + u_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}\right) = 1 - \alpha \quad n > \frac{9}{p(1-p)}$$

$$\text{Excel: } u_{1-\frac{\alpha}{2}} = \text{NORM.S.INV}(1 - \frac{\alpha}{2})$$



Jednovýběrové testy

z-test $\mu = \mu_0$

testovací kritérium $T(X) : \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$ normalita nebo $n > 30$

t-test $\mu = \mu_0$

testovací kritérium $T(X) : \frac{\bar{x} - \mu_0}{s} \sqrt{n} \sim t_{n-1}$ normalita

test o rozptylu $\sigma^2 = \sigma_0^2$

testovací kritérium $T(X) : \frac{(n-1)s^2}{\sigma_0^2} \sim \chi_{n-1}^2$ normalita

test o parametru binomického rozdělení $\pi = \pi_0$

testovací kritérium $T(X) : \frac{p - \pi_0}{\sqrt{\pi_0(1 - \pi_0)}} \sqrt{n} \sim N(0, 1)$ normalita

znaménkový test $x_{0.5} = c$

testovací kritérium $T(X) : \text{počet kladných odchylek od } c$ $n > 10$
nulové rozdělení: $Bi(n, \pi = 0.5)$

Wilcoxonův test $x_{0.5} = c$

testovací kritérium $T(X) : \min(R^+, R^-)$

$R^+ = \sum_{x_i - c \geq 0} R_i, R^- = \sum_{x_i - c < 0} R_i$, kde R_i je pořadí seřazených odchylek od c

kritická hodnota: $w_n(\alpha)$ je tabelována

Dvouvýběrové testy – dva závislé výběry

párový t-test $\mu_1 = \mu_2$

platí: $n_1 = n_2 = n$

testovací kritérium $T(X) : \frac{\bar{d} \sqrt{n-1}}{s_d} \sim t(n-1)$, kde

\bar{d} je průměr hodnot $d_i = x_{1i} - x_{2i}$

s_d je směrodatná odchylka hodnot d_i

párový Wilcoxonův test $x_{0.5} = y_{0.5}$

platí: $n_x = n_y = n$

určíme $z_i = x_i - y_i$

převědeme na jednovýběrový Wilcoxonův test s $H_0 : z_{0.5} = 0$

Dvouvýběrové testy – dva nezávislé výběry

F-test $\sigma_1^2 = \sigma_2^2$

testovací kritérium $T(X) : \frac{s_1^2}{s_2^2} \sim F(n_1 - 1, n_2 - 1), s_1^2 > s_2^2$

nepárový t-test $\mu_1 = \mu_2$

1) platí $\sigma_1^2 = \sigma_2^2$

testovací kritérium $T(X) : \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2} \frac{n_1+n_2}{n_1 n_2}}} \sim t_{n_1+n_2-2}$

2) neplatí $\sigma_1^2 = \sigma_2^2$

testovací kritérium $T(X) : \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \sim t_\nu$, kde $\nu = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}\right)^2}{\frac{1}{n_1-1} \left(\frac{s_1^2}{n_1}\right)^2 + \frac{1}{n_2-1} \left(\frac{s_2^2}{n_2}\right)^2}$

Mannův-Whitneyho test $x_{0.5}^1 = x_{0.5}^2$

pozorování dohromady seřadíme, T_i značí součet pořadí hodnot i -tého souboru

testovací kritérium $T(X) : \min(U_1, U_2)$, kde

$U_1 = n_1 n_2 + \frac{n_1(n_1+1)}{2} - T_1, U_2 = n_1 n_2 + \frac{n_2(n_2+1)}{2} - T_2$

kritické hodnoty tabelovány

ANOVA

nulová hypotéza $\mu_1 = \mu_2 = \dots = \mu_k$

předpoklad: normalita a homoskedasticita ($\sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2$)

testovací kritérium $T(X) : \frac{M_G}{M_R} \sim F_{k-1, n-k}$, kde $M_G = \frac{S_G}{df_G}$ a $M_R = \frac{S_R}{df_R}$

součet čtverců, stupně volnosti

$S_G = \sum_{i=1}^k n_i (\bar{x}_i - \bar{x})^2, df_G = k - 1$ mezi skupinami

$S_R = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2, df_R = n - k$ reziduální

$S_T = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2, df_T = n - 1$ celkový