

Porovnání 2 výběrů

máme X_1, \dots, X_m výběr z $N(\mu_1, \sigma_1^2)$

Y_1, \dots, Y_m výběr z $N(\mu_2, \sigma_2^2)$

možné hypotézy: $H: \mu_1 = \mu_2$ proti $A: \mu_1 > \mu_2$ ($\mu_1 < \mu_2, \mu_1 \neq \mu_2$)
 $H: \sigma_1^2 = \sigma_2^2$ proti $A: \sigma_1^2 > \sigma_2^2$ ($\sigma_1^2 < \sigma_2^2, \sigma_1^2 \neq \sigma_2^2$)

posuzová se klamě:

parný t-test pro $H: \mu_1 = \mu_2$ v případě, že $\sigma_1^2 \neq \sigma_2^2$ nebo výběry nejsou na sobě nezávislé

dvouběhový t-test pro $H: \mu_1 = \mu_2$ v případě, že výběry jsou nezávislé a $\sigma_1^2 = \sigma_2^2$

případně jako modifikace po nestyčné rozptylech předpoklad nezávislosti musí platit vždy

F-test pro $H: \sigma_1^2 = \sigma_2^2$ na předpokladu nezávislosti výběrů

Parný t-test

vytvoří se rozdílů $Z_1 = X_1 - Y_1, \dots, Z_m = X_m - Y_m$, kde $m = \min(m_1, m_2)$

Z_1, \dots, Z_m jsou nezávislé, mají rozdělení $N(\mu_1 - \mu_2, \sigma^2)$
(σ^2 máš nezajímá)

oznámíme $\Delta = \mu_1 - \mu_2$

test $H: \mu_1 = \mu_2$ proti $A: \mu_1 > \mu_2$ ($\mu_1 < \mu_2, \mu_1 \neq \mu_2$)

je kolinný otestem (jednorozměrným)

$H: \Delta = 0$ proti $A: \Delta > 0$ ($\Delta < 0, \Delta \neq 0$)

Dvoupřerový t-test při stejné rozptylech

je kalorický má veličině $\bar{X} - \bar{Y} \sim N(\mu_1 - \mu_2, \frac{\sigma^2}{n} + \frac{\sigma^2}{m})$

platí $\frac{(n-1)S_x^2}{\sigma^2} + \frac{(m-1)S_y^2}{\sigma^2} \sim \chi^2_{m+n-2}$

α loba $\frac{\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\sigma^2/n + \sigma^2/m}}}{\sqrt{\frac{(n-1)S_x^2}{\sigma^2} + \frac{(m-1)S_y^2}{\sigma^2}}}$ $\sim t_{m+n-2}$

ko se upraví $\frac{\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{(m+n)/mm}}}{\sqrt{\frac{(n-1)S_x^2 + (m-1)S_y^2}{m+n-2}}} = \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{(n-1)S_x^2 + (m-1)S_y^2}} \cdot \sqrt{\frac{mm(m+n-2)}{m+n}}$

ko se porovná s kritickou hodnotou t_{m+n-2} - rozdělení má hl. α

Test shodnosti rozptylů

je kalorický má podílem $\frac{S_x^2}{S_y^2}$ - v případě shodnosti rozptylů by to měla být přibližně 1

platí $\frac{S_x^2}{S_y^2} \sim F_{m-1, m-1}$

H: $\sigma_1^2 = \sigma_2^2$ proti A: $\sigma_1^2 \neq \sigma_2^2$ se namíká, když

$\frac{S_x^2}{S_y^2} \leq k_1$, nebo $\frac{S_x^2}{S_y^2} \geq k_2$

kde k_1, k_2 se určí z podmínek

$P(\frac{S_x^2}{S_y^2} \leq k_1) = \frac{\alpha}{2}$, $P(\frac{S_x^2}{S_y^2} \geq k_2) = \frac{\alpha}{2}$

$$\frac{\alpha}{2} = P\left(\frac{S_x^2}{S_y^2} \leq k_1\right) = 1 - P\left(\frac{S_x^2}{S_y^2} \geq k_1\right)$$

$$\Rightarrow P\left(\frac{S_x^2}{S_y^2} \geq k_1\right) = 1 - \frac{\alpha}{2} \Rightarrow k_1 \text{ je kritická hodnota}$$

$$f'_{n-1, m-1, 1-\alpha/2} = \frac{1}{f'_{m-1, n-1, \alpha/2}}$$

$$\frac{\alpha}{2} = P\left(\frac{S_x^2}{S_y^2} \geq k_2\right) \Rightarrow k_2 = f'_{n-1, m-1, \alpha/2}$$

v případě, že $S_x^2 \geq S_y^2$, stačí porovnat s k_2

(v opačném případě položíme pořadí výšší)

test nezávislosti výher

máme náhodný výher X_1, \dots, X_m , který realizuje veličinu $X \sim N(\mu_1, \sigma_1^2)$
 - - - Y_1, \dots, Y_m - - - $Y \sim N(\mu_2, \sigma_2^2)$

předpokládá se, že veličiny X, Y mají sdružené 2-rozměrné normální rozdělení

mírou závislosti mezi X a Y je jejich kovariance

def: $cov(X, Y) = E(X - EX)(Y - EY)$

jestliže X, Y nezávislé, je $cov(X, Y) = 0$ (v případě normálního rozdělení platí i naopak)

$$cov(X, Y) = E(X - EX)(Y - EY) = EXY - 2EXEY + EXEY = EXY - EXEY = 0$$

normovaná kovariance se nazývá korelace

def. korelační koeficient $\rho = \frac{cov(X, Y)}{\sqrt{var X var Y}}$

rovně $\rho = 0 \Leftrightarrow \text{cov}(X, Y) = 0$ po nerovnosti máh. veličiny

jinak platí $-1 \leq \rho \leq 1$, neboť $|\text{cov}(X, Y)| = |E(X - EX)(Y - EY)| \leq$
 $\leq \sqrt{E(X - EX)^2 E(Y - EY)^2} = \sqrt{\text{var} X \text{var} Y}$ (Schwarzova nerovnost)

test nerovnosti v normálním rozdělení je tedy test $H_0: \rho = 0$

test je založen na odhadu (testový korelační koeficient)

$$r = \frac{S_{XY}}{\sqrt{S_X^2 S_Y^2}}, \text{ kde } S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

po úpravě dostaneme

$$r = \frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{\sqrt{(\sum X_i^2 - n \bar{X}^2)(\sum Y_i^2 - n \bar{Y}^2)}}$$

existují tabulky kritických hodnot pro test $H_0: \rho = 0$ proti $H_1: \rho \neq 0$

s vlastností $P(|r| \geq r_\alpha) = \alpha$

ověřování normálního rozdělení

t-testy obvykle nejsou na porušení normality příliš citlivé

existuje χ^2 -test dobré shody

test založený na výběrových momentech (šikmosti a špičatosti)

můžeme se k nim dostat

Kolmogorov - Smirnovův test

Ověřování normality rozdělení

Předpokládáme, že X_1, \dots, X_n je náhodný výběr z rozdělení se střední hodnotou μ a rozptylem σ^2 (oba parametry známe).

Hypotéza: X_1, \dots, X_n je náh. výběr z $N(\mu, \sigma^2)$

Použijeme Pearsonův χ^2 -test dobré shody.

Oba hodnot náhodné veličiny X rozdělíme na k intervalů:

$$(-\infty, t_1), (t_1, t_2), (t_2, t_3) \dots, (t_{k-1}, \infty)$$

vypočítáme, kolik pozorování padne do každého intervalu:

$$m_i = \text{počet pozorování, která padnou do } (t_{i-1}, t_i)$$

číselné relativní četnosti budou $\frac{m_i}{n}$

teoretické pravděpodobnosti $p_i = P(t_{i-1} \leq X < t_i)$ se dají

při známých parametrech přímě spočítat:

$$p_i = P(t_{i-1} \leq X < t_i) = \Phi\left(\frac{t_i - \mu}{\sigma}\right) - \Phi\left(\frac{t_{i-1} - \mu}{\sigma}\right),$$

kde Φ je distrib. fce rozdělení $N(0, 1)$

Na platnosti hypotézy by měly být hodnoty p_i a $\frac{m_i}{n}$ přibližně stejné.

Použije se testová statistika

$$\chi^2 = \sum_{i=1}^k \frac{(m_i - np_i)^2}{np_i} = \sum_{i=1}^k \frac{m_i^2}{np_i} - n = \frac{1}{n} \sum_{i=1}^k \frac{m_i^2}{p_i} - n$$

klasa' ma' na pravode hypotézy rozdělení χ^2_{k-1} .

Hypotéza se zamítá, když $\chi^2 \geq \chi^2_{k-1}(\alpha)$, kde $\chi^2_{k-1}(\alpha)$ je kritická hodnota na hladině α .

Poznámky:

- Testní kritérium se dá ověřit shoda s jakýmkoli rozdělením - místo ϕ se používá příslušná distribuční funkce.
- Problémem je znalost hodnot parametrů - ty obvykle nejsou předem známy a musí se nějakým způsobem odhadnout (existuje test χ^2 dobré shody při neshodných parametrech, je komplikovanější).
- Test je pouze asymptotický, aplikace χ^2 -rozdělením je dobrá, pokud je $n p_i \geq 5$ po každé i .

Princip odhadu nejmenších parametrů:

pravděpodobnosti p_i jsou funkcemi μ a σ^2 , tj.:

$$p_i = p_i(\mu, \sigma) = \Phi\left(\frac{t_i - \mu}{\sigma}\right) - \Phi\left(\frac{t_{i-1} - \mu}{\sigma}\right) = \int_{t_{i-1}}^{t_i} f(x) dx,$$

$$\text{kde } f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (\text{ hustota })$$

Pedevším se předpokládá hypotézy o středci malé hustoty γ^2 , hledají se μ a σ tak, aby γ^2 bylo minimální, tj. řeší se rovnice

$$\frac{\partial \gamma^2}{\partial \mu} = 0 \quad \text{a} \quad \frac{\partial \gamma^2}{\partial \sigma} = 0, \quad \text{kde } \gamma^2 = \sum_{i=1}^k \frac{(x_i - m p_i(\mu, \sigma))^2}{m p_i(\mu, \sigma)}.$$

Přesné řešení je ale složité, používají se různá zjednodušení těchto rovnic (míllere členy se zanedbávají) a málokdy se stejně řeší iterací.

n. n.

Jednoduchý Kolmogorov - Smirnovův test:

X_1, \dots, X_n je náhodný výběr n nezávisle rozdělené se společnou distribuční fceí
testujeme hypotézu, že tato distribuční fce je F

vypočteme F_n - empirická distr. fce:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \xi_i(x), \text{ kde } \xi_i(x) = \begin{cases} 1, & \text{je-li } X_i \leq x \\ 0, & \text{je-li } X_i > x \end{cases}$$

platí: $F_n(x) \rightarrow F(x)$ skoro jistě pro $n \rightarrow \infty$

položíme $D_n = \sup_x |F_n(x) - F(x)|$

se úspěchy hypotézy měří malé hodnoty D_n

hypotéza se zamítá, když $D_n \geq D_n(\alpha)$... kritická hodnota

kritické hodnoty lze najít tabelováním

pro velká n jsou přibližně $D_n(\alpha) \approx \sqrt{\frac{1}{2n} \ln \frac{2}{\alpha}}$

Poznámky:

- 1) Empirická distr. fce je složená, stačí tedy hodnoty D_n počítat a hledat, kde má šok (musí se vyšetřit i kritický význam) %.
- 2) Poliv je, když nejsou znány parametry testované distribuční funkce. Musí se odhadovat z výběru, ale čím se měří rozdělení testové statistiky a kritické hodnoty se pak počítají na základě simulačních studií.