

1 8-Parametrické úlohy o dvou nezávislých náhodných výběrech z normálního rozložení

Vyjádření k domácímu úkolu

- interpretace koeficientu korelace: $r = 0.8 \rightarrow$ vysoký stupeň PŘÍMÉ LINEÁRNÍ závislosti
- u testování hypotéz nezapomínejte stanovit H_0, H_1 , a psát celkový závěr příkladu!!!
- testování pomocí IS: $H_0 : \mu = c \rightarrow H_0$ nezamítáme, pokud $c \in IS$.

Stará látka

- přehled testů - rozdat
- Testování hypotéz
 - datový soubor reálných dat
 - máme předpoklady o datovém souboru: o charakteristikách, o rozložení náh. veličiny, o nezávislosti dvou náh. veličin
 - zatím jsme ověřovali *předpoklady o charakteristikách* jednovýběrových dat (μ, σ) z normálního rozložení
 - postup testování hypotéz
 - * Formulace problému
 - * stanovení H_0
 - * stanovení H_1
 - oboustranná
 - pravostranná
 - levostanná
 - * volba hl.významnosti $\alpha = \text{pst}$, že H_0 zamítáme, i když platí.
 - * provedení měření
 - * testování hypotéz
 - Kritický obor
 - IS
 - p-hodnota
 - * rozhodnutí o zamítnutí H_0
 - * INTERPRETACE VÝSLEDKŮ
 - chyba 1.druhu: H_0 platí a přesto ji zamítneme
 - chyba 2.druhu: H_0 neplatí a přesto ji nezamítneme
- kritický obor
 - stanovíme T_0
 - stanovíme kritický obor W - tvar podle typu alternativy

- H_0 zamítáme, pokud $T_0 \in W$.

- IS:

- z H_0 známe konstantu c
- stanovíme IS - tvar podle alternativy: A/IS: O/O, L/P, P/L
- H_0 zamítáme, pokud $c \notin IS$

- p-hodnota

- stanovíme T_0
- stanovíme p-hodnotu podle typu alternativy
- H_0 zamítáme, pokud $p < \alpha$.

Nová látka

Párové testy:

- data z dvouozměrného normálního rozložení
- porovnání rozdílů párových součástí objektu, párových orgánů člověka
- porovnání délky uší, výšky/šířky očí, nadočnicového oblouku, sjetost pneumatik, zkoumání podobných rysů dvojčat atp.
- Nechť $(X_1, Y_1) \dots (X_n, Y_n)$ je náh. výběr z dvouozměrného normálního rozložení, přičemž $n \geq 2$. Střední hodnota znaku X je μ_1 , střední hodnota znaku Y je μ_2 .
- $H_0 : \mu_1 = \mu_2 : \mu_1 - \mu_2 = 0$
- $H_1 : \mu_1 \neq \mu_2 : \mu_1 - \mu_2 \neq 0$
- utvoříme rozdíly $Z_1 = X_1 - Y_1 \dots Z_n = X_n - Y_n$.
- Z_1, \dots, Z_n je datový soubor z normálního rozložení \rightarrow získáváme jednovýběrový datový soubor
- aplikujeme jednovýběrový test o střední hodnotě μ , když σ^2 neznáme.
- Příklad z domácího úkolu (*viz příloha sken1*)

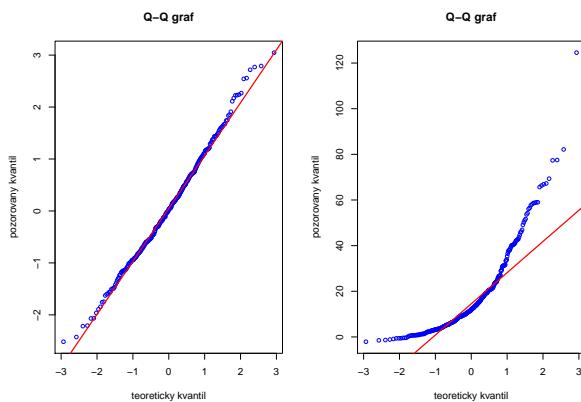
Testování normality

- normalita dat je velmi důležitá vlastností datového souboru
- pro mnoho parametrických testů je předpoklad normality důležitým základem
 - jednovýběrové testy
 - párové testy
 - dvouvýběrové testy, ...
- testování normality datového souboru

- Testujeme nulovu hypotézu: H_0 : Datový soubor/data pochází z normálního rozložení
- alternativní hypotéza: H_0 : Data nepochází z normálního rozložení
- testování provádíme

1. graficky

- histogram + křivka hustoty teoretického normálního rozložení s odhadem střední hodnoty $\mu = \text{mean}(\text{data})$ a odhadem rozptylu $\sigma^2 = (\text{sd}(\text{data}))^2$ + křivka hustoty odhadnutá z dat `density(vektor_dat)`.
- krabicový graf - více než normalitu testuje vyšikmenost dat `boxplot()`
- Q-Q graf příkazy `qqnorm(vektor_dat)` a `qqline(vektor_dat)`



Obrázek 1: a)vlevo-body leží na přímce → data jsou z normálního rozložení; b)-vpravo - body neleží na přímce → data nejsou z normálního rozložení

2. početně - testováním

- Shapiro-Wilkův test
 - * je vhodný pro testování souborů o menších rozsahů ($n \leq 30$)
 - * `shapiro.test()` knihovna `stat`
- Kolmogorův-Smirnovův test
- Lillie-Forsův test
 - * modifikace K-S testu
 - * `lillie.test()` knihovna `nortest`
- Anderson-Darlingův test
 - * `ad.test()` knihovna `nortest`
- Pearsonův χ^2 test
 - * `pearson.test` knihovna `nortest`

– vždy je vhodné provést alespoň dva testy normality

- ODTEĎ PŘED KAŽDÝM TESTOVÁNÍM POMOCÍ PARAMETRICKÝCH TESTŮ MUSÍME OVĚŘIT NORMALITU DAT

Testy o dvou nezávislých náhodných výběrech

Nechť $X_{11} \dots X_{1n_1}$ je náhodný výběr z rozložení $N(\mu_1, \sigma_1^2)$ a $X_{21} \dots X_{2n_2}$ je na něm nezávislý náhodný výběr z rozložení $N(\mu_2, \sigma_2^2)$, přičemž $n_1 \geq 2$ a $n_2 \geq 2$. Označme M_1, M_2 výběrové průměry a S_1^2, S_2^2 výběrové rozptyly a

$$S_*^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

je vážený průměr výběrových rozptylů.

1. Pivotová statistika

$$U = \frac{(M_1 - M_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0, 1)$$

slouží k řešení úloh o $\mu_1 - \mu_2$, když σ_1^2 a σ_2^2 známe.

2. Pokud $\sigma_1^2 = \sigma_2^2 = \sigma^2$, pak pivotová statistika

$$K = \frac{(n_1 + n_2 - 2)S_*^2}{\sigma^2} \sim \chi^2(n_1 + n_2 - 2)$$

slouží k řešení úloh o neznámém společném rozptylu σ^2 .

3. Pokud $\sigma_1^2 = \sigma_2^2 = \sigma^2$, pak pivotová statistika

$$T = \frac{(M_1 - M_2) - (\mu_1 - \mu_2)}{S_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2)$$

slouží k řešení úloh o $\mu_1 - \mu_2$, když σ_1^2, σ_2^2 neznáme, ale víme, že jsou shodné.

4. Pivotová statistika

$$F = \frac{S_1^2/S_2^2}{\sigma_1^2/\sigma_2^2} \sim F(n_1 - 1, n_2 - 1)$$

slouží k řešení úloh o $\frac{\sigma_1^2}{\sigma_2^2}$.

Intervaly spolehlivosti

1. IS pro $\mu_1 - \mu_2$, když σ_1^2, σ_2^2 známe (využití statistiky U)

(a) Oboustranný IS (d, h) :

$$\left(m_1 - m_2 - \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} u_{1-\alpha/2}; m_1 - m_2 - \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} u_{\alpha/2} \right)$$

(b) Levostranný IS $(d; \infty)$:

$$\left(m_1 - m_2 - \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} u_{1-\alpha}; \infty \right)$$

(c) Pravostranný IS $(-\infty; h)$:

$$\left(-\infty; m_1 - m_2 - \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} u_{\alpha} \right)$$

2. IS pro $\mu_1 - \mu_2$, když σ_1^2, σ_2^2 neznáme, ale víme, že jsou shodné (využití statistiky T)

(a) Oboustranný IS (d, h) :

$$\left(m_1 - m_2 - s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} t_{1-\alpha/2}(n_1 + n_2 - 2); m_1 - m_2 - s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} t_{\alpha/2}(n_1 + n_2 - 2) \right)$$

(b) Levostranný IS $(d; \infty)$:

$$\left(m_1 - m_2 - s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} t_{1-\alpha}(n_1 + n_2 - 2); \infty \right)$$

(c) Pravostranný IS $(-\infty; h)$:

$$\left(-\infty; m_1 - m_2 - s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} t_{\alpha}(n_1 + n_2 - 2) \right)$$

3. IS pro společný neznámý rozptyl σ^2 (využití pivotové statistiky K)

(a) Oboustranný IS (d, h) :

$$\left(\frac{(n_1 + n_2 - 2)s_*^2}{\chi_{1-\alpha/2}^2(n_1 + n_2 - 2)}; \frac{(n_1 + n_2 - 2)s_*^2}{\chi_{\alpha/2}^2(n_1 + n_2 - 2)} \right)$$

(b) Levostranný IS (d, ∞)

$$\left(\frac{(n_1 + n_2 - 2)s_*^2}{\chi_{1-\alpha}^2(n_1 + n_2 - 2)}; \infty \right)$$

(c) Pravostranný IS $(-\infty; h)$

$$\left(-\infty; \frac{(n_1 + n_2 - 2)s_*^2}{\chi_{\alpha}^2(n_1 + n_2 - 2)} \right)$$

4. IS pro podíl rozptylů $\frac{\sigma_1^2}{\sigma_2^2}$ (využití pivotové statistiky F)

(a) Oboustranný IS (d, h) :

$$\left(\frac{s_1^2/s_2^2}{F_{1-\alpha/2}(n_1 - 1, n_2 - 1)} ; \frac{s_1^2/s_2^2}{F_{\alpha/2}(n_1 - 1, n_2 - 1)} \right)$$

(b) Levostranný IS $(d; \infty)$

$$\left(\frac{s_1^2/s_2^2}{F_{1-\alpha}(n_1 - 1, n_2 - 1)} ; \infty \right)$$

(c) Pravostranný IS $(-\infty; h)$

$$\left(-\infty ; \frac{s_1^2/s_2^2}{F_{\alpha}(n_1 - 1, n_2 - 1)} \right)$$

Dvouvýběrové testy - Kritické obory

1. Nechť X_{11}, \dots, X_{1n_1} je náhodný výběr z $N(\mu_1, \sigma_1^2)$, a X_{21}, \dots, X_{2n_2} je na něm nezávislý náhodný výběr z rozložení $N(\mu_2, \sigma_2^2)$, přičemž $n_1 \geq 2$, $n_2 \geq 2$ a σ_1^2, σ_2^2 známe. Nechť c je konstanta.

- Testujeme $H_0 : \mu_1 - \mu_2 = c$ oproti $H_{11} : \mu_1 - \mu_2 \neq c$, případně $H_{12} : \mu_1 - \mu_2 < c$, či $H_{13} : \mu_1 - \mu_2 > c$.
- Takovýto test se nazývá *dvouvýběrový z-test*
- Realizace testové statistiky:

$$t_0 = \frac{(m_1 - m_2) - c}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}.$$

- kritický obor pro oboustrannou alternativu H_{11} : $W = (-\infty; u_{\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$
- kritický obor pro levostrannou alternativu H_{12} : $W = (-\infty; u_\alpha)$
- kritický obor pro pravostrannou alternativu H_{13} : $W = (u_{1-\alpha}; \infty)$

2. Nechť X_{11}, \dots, X_{1n_1} je náhodný výběr z $N(\mu_1, \sigma^2)$, a X_{21}, \dots, X_{2n_2} je na něm nezávislý náhodný výběr z rozložení $N(\mu_2, \sigma^2)$, přičemž $n_1 \geq 2$, $n_2 \geq 2$ a σ^2 neznáme. Nechť c je konstanta.

- Testujeme $H_0 : \mu_1 - \mu_2 = c$ oproti $H_{11} : \mu_1 - \mu_2 \neq c$, případně $H_{12} : \mu_1 - \mu_2 < c$, či $H_{13} : \mu_1 - \mu_2 > c$.
- Takovýto test se nazývá *dvouvýběrový t-test*
- Realizace testové statistiky:

$$t_0 = \frac{(m_1 - m_2) - c}{s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}.$$

- kritický obor pro oboustrannou alternativu H_{11} : $W = (-\infty; t_{\alpha/2}(n_1+n_2-2)) \cup (t_{1-\alpha/2}(n_1+n_2-2), \infty)$
- kritický obor pro levostrannou alternativu H_{12} : $W = (-\infty; t_\alpha(n_1+n_2-2))$
- kritický obor pro pravostrannou alternativu H_{13} : $W = (t_{1-\alpha}(n_1+n_2-2); \infty)$

3. Nechť X_{11}, \dots, X_{1n_1} je náhodný výběr z $N(\mu_1, \sigma^2)$, a X_{21}, \dots, X_{2n_2} je na něm nezávislý náhodný výběr z rozložení $N(\mu_2, \sigma^2)$, přičemž $n_1 \geq 2$, $n_2 \geq 2$.

- Testujeme $H_0 : \frac{\sigma_1^2}{\sigma_2^2} = 1$ oproti $H_{11} : \frac{\sigma_1^2}{\sigma_2^2} \neq 1$.
- Takovýto test se nazývá *F-test*.
- Realizace testové statistiky:

$$t_0 = \frac{s_1^2}{s_2^2}$$

- kritický obor pro oboustrannou alternativu H_{11} : $W = (0; F_{\alpha/2}(n_1-1, n_2-1)) \cup (F_{1-\alpha/2}(n_1-1, n_2-1), \infty)$

- kritický obor pro levostrannou alternativu H_{12} : $W = (0; F_\alpha(n_1 - 1, n_2 - 1))$
- kritický obor pro pravostrannou alternativu H_{13} : $W = \langle F_{1-\alpha}(n_1 - 1, n_2 - 1); \infty \rangle$