

Matematická statistika A

2014

Outline

1 Úvod, struktura přednášky

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmu

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadové
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy
- 4 II.2. Pořadová statistiky pro test hypotézy symetrie

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy
- 4 II.2. Pořadová statistiky pro test hypotézy symetrie
- 5 II.3. Dvouvýběrový problém

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy
- 4 II.2. Pořadová statistiky pro test hypotézy symetrie
- 5 II.3. Dvouvýběrový problém

Outline

Úvod,
struktura
přednáškyI. Opakování
základních
pojmůII. Pořadové
testyII.2. Pořadová
statistiky pro
test hypotézy
symetrieII.3.
Dvouvýběrový
problém

Hlavní kapitoly:

- I. Opakování základů pravděpodobnosti a mat. statistiky
- II. Testy založené na pořadích
- III. Mnohorozměrná statistika
- IV. Neparametrická regrese
- V. Resampling metody
- VI. Základy Bayesovského přístupu k řešení statistických problémů (bude-li čas, popř. jiné téma)

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy
- 4 II.2. Pořadová statistiky pro test hypotézy symetrie
- 5 II.3. Dvouvýběrový problém

I. Opakování základních pojmů

Literatura pro úvod

K. Zvára, J. Štěpán: Pravděpodobnost a matematická statistika, Matfyzpress 1997

J. Anděl: Statistické metody, Matfyzpress 1993

R. Bartoszyński, M. Nuewiadomska-Bugaj, Wiley 1996

Pro další části bude literatura postupně doplňována

pravděpodobnost P -míra na (Ω, \mathcal{A}) , A -jevy,
 $0 \leq P(A) \leq 1, P(\Omega) = 1, P(A \cup B) = P(A) + P(B) - P(A \cap B)$

nahodná veličina $X : \Omega \rightarrow R^1$

distribuční funkce náhodné veličiny

střední hodnota

rozptyl

binomické rozdělení, normalní rozdělení, t-rozdělení,

centralní limitní věta a její použití

základy teorie odhadu a testování hypotéz, některé základní
odhady a testy

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy**
- 4 II.2. Pořadová statistiky pro test hypotézy symetrie
- 5 II.3. Dvouvýběrový problém

Outline

Úvod,
struktura
přednáškyI. Opakování
základních
pojmů**II. Pořadové
testy**II.2. Pořadová
statistiky pro
test hypotézy
symetrieII.3.
Dvouvýběrový
problém

II. Pořadové testy

II. 1. Základní pojmy

pořadí, základní vlastnosti, lineární pořadové statistiky,

II.2 Pořadová statistika pro test hypotézy symetrie

II.3 Pořadové statistiky pro dvouvýběrový problém

obecný test, jednovýběrový Wilcoxonův test a jeho vlastnosti, znaménkový test

obecný test, Wilcoxonův test a jeho vlastnosti, mediánový test, kvartilový test

II.4 Některé další používané pořadové testy

Kruskal -Wallisův test, Friedmanův test, Spearmanův korelační koeficient,
Kolmogorov-Smirnovovy statistiky

II.1 Základní pojmy

Nechť X_1, \dots, X_n jsou nezávislé náhodné veličiny se spojitou distribuční funkcí F ,

R_i – pořadí X_i mezi X_1, \dots, X_n , $i = 1, \dots, n$

Platí $P(X_i = X_j) = 0$, $i \neq j$

Příklad

X_i 53 48 45 55 63 51 66 56 50 58

R_i 05 02 01 06 09 04 10 07 03 08

Pořadové testy jsou založeny na R_1, \dots, R_n , jednoduché, mají řadu výhod, ale ztrácíme část informace

Věta 1 Necht X_1, \dots, X_n jsou nezávislé náhodné veličiny se spojitou distribuční funkcí F . Pak platí

$$P(R_1 = r_1, \dots, R_n = r_n) = \frac{1}{n!}, \quad (r_1, \dots, r_n) \text{ permutace } 1, \dots, n,$$

$$P(R_i = j) = \frac{1}{n}, \quad i, j = 1, \dots, n$$

$$P(R_1 = r_1, R_2 = r_2) = \frac{1}{n(n-1)}, \quad i \neq j \quad 1 \leq r_i, r_j \leq n \quad r_i \neq r_j$$

$$E R_i = (n+1)/2, \quad i = 1, \dots, n$$

$$\text{var } R_i = \frac{1}{n-1} \sum_{j=1}^n j^2 - \frac{1}{n-1} \left(\frac{n+1}{2} \right)^2$$

Důkaz Počet permutací čísel $1, \dots, n$ je $n!$.

$$P(R_i = j) = \frac{(n-1)!}{n!}$$

$$E R_i = \sum_{j=1}^n j P(R_i = j) = \frac{1}{n} \frac{n(n+1)}{2} = \frac{n+1}{2}$$

Outline

Úvod,
struktura
přednáškyI. Opakování
základních
pojmů**II. Pořadové
testy**II.2. Pořadová
statistiky pro
test hypotézy
symetrieII.3.
Dvouvýběrový
problém

Rozdělení R_1, \dots, R_n nezávisí na $F!!!$

Definujeme *lineární pořadovou statistiku* předpisem

$$S = \sum_{i=1}^n c_i a(R_i),$$

kde c_1, \dots, c_n a $a(1), \dots, a(n)$ jsou daná čísla, např.
 $a(i) = i, i^2, \dots$

Věta 2 Za předpokladu předchozí věty platí

$$E S = \frac{1}{n} \sum_{i=1}^n c_i \sum_{j=1}^n a(j)$$

$$\text{var } S = \frac{1}{n-1} \sum_{i=1}^n (c_i - \bar{c}_n)^2 \sum_{j=1}^n (a(j) - \bar{a}_n)^2$$

kde

$$\bar{c}_n = \frac{1}{n} \sum_{i=1}^n c_i, \quad \bar{a}_n = \frac{1}{n} \sum_{j=1}^n a(j).$$

Důkaz Platí:

$$E a^v(R_i) = \frac{1}{n} \sum_{j=1}^n a^v(j), \quad v = 1, 2, \dots,$$

$$E a(R_1)a(R_2) = \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j=1, j \neq i}^n a(j)a(i)$$

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém



Jiná pořadová statistika - pořadová statistika pro hypotézu symetrie:

$$S^+ = \sum_{i=1}^n a(R_i^+) \text{sign } X_i$$

kde R_i^+ je pořadí $|X_i|$ mezi $|X_1|, \dots, |X_n|$ a
 $\text{sign } x = 1, x > 0; = -1, x < 0; = 0, x = 0$.

Věta 3 Necht' jsou splněny předpoklady věty 1 a necht' $F(x) + F(-x) = 1, x \in R^1$. Pak jsou $|X_i|$ a $\text{sign } X_i$ nezávislé náhodné veličiny. Nezávislé Navíc, náhodné vektory (R_1^+, \dots, R_n^+) a $(\text{sign } X_1, \dots, \text{sign } X_n)$ jsou nezávislé.

Důkaz Platí pro $x > 0$:

$$P(|X_1| < x, \text{sign } X_1 = 1) = P(0 < X_1 < x) = F(x) - F(0),$$

$$P(|X_1| < x) = P(-x < X_1 < x) = F(x) - F(-x) = 2F(x) - 1,$$

$$P(\text{sign } X_1 = 1) = P(X_1 > 0) = 1/2, \quad F(0) = 1/2$$

Tedy

$$P(|X_1| < x, \text{sign } X_1 = 1) = P(|X_1| < x)P(\text{sign } X_1 = 1)$$

Podobně pro $P(|X_1| < x, \text{sign } X_1 = -1)$. □

Věta 4 Necht' jsou splněny předpoklady věty 3. Pak

$$E S^+ = 0, \quad \text{var } S^+ = \frac{1}{n} \sum_{j=1}^n a^2(j)$$

Důkaz Platí $E S^+ = \sum_{i=1}^n \left(E \text{sign } X_i \right) \left(E a(R_i^+) \right)$

$$E \text{sign } X_i = 0$$

$$\text{var } S^+ = \dots$$

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy
- 4 **II.2. Pořadová statistiky pro test hypotézy symetrie**
- 5 II.3. Dvouvýběrový problém

Outline

Úvod,
struktura
přednáškyI. Opakování
základních
pojmůII. Pořadové
testyII.2. Pořadová
statistiky pro
test hypotézy
symetrieII.3.
Dvouvýběrový
problém

II.2. Pořadová statistiky pro test hypotézy symetrie

X_1, \dots, X_n nezávislé stejně rozdělené náh. veličiny s distr. fcí F

Hypotéza symetrie: formulace

$$H_0 : F(x) + F(-x) = 1, \quad x \in \mathbb{R}^1$$

ex.-li hustota f pak

$$H_0 : f(x) = f(-x), \quad x \in \mathbb{R}^1 \quad (\text{az } \text{Leb. } \text{miru } 0)$$

v tomto případě je *medián* roven 0

zobecnění: ex. a reálné, že $f(x + a) = f(a - x)$ pro vš. x

alternativní hypotéza: H_0 neplatí

používají se mimo jiné testy založené na S^+

motivace pro H_0 a klasický t-test

dvojice nezávislých pozorování $(Y_1, Z_1), \dots, (Y_n, Z_n)$,
 (Y_i, Z_i) má distribuční funkci $F(y, z)$

Z_i – odpovídá ošetření (zdravotní stav před léčbou)

Y_i – odpovídá kontrole (zdravotní stav po léčbou)

$H_0 : F(y, z) = F(z, y)$ pro vš. y, z

tedy ošetření nemá vliv, popř. léčba nemá vliv na zdravotní stav

často definujeme: $X_i = Y_i - Z_i, i = 1, \dots$

G – distr. fce náhodné veličiny X_i

pak $H_0 : G(x) + G(-x) = 1$

je-li G distribuční fce $N(\mu, \sigma^2)$, $\mu \in \mathbb{R}^1$ and $\sigma^2 > 0$ neznámé

pak $H_0 : \mu = 0$ a aplikujeme tzv. jednovýběrový t-test

testová statistika:

$$T = \frac{\bar{X}_n}{s_n(x)} \sqrt{n}$$

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i, \quad s_n^2(x) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

zamítáme na hladině α , jestliže

$$|T| \geq t_{n-1, 1-\alpha/2}$$

kde $t_{n-1, 1-\alpha/2}$ je kvantil t -rozdělení on $n - 1$ stupních volnosti

Test je vhodný, pokud je splněn předpoklad normality nebo je n dost velké a jsou konečné momenty (centrální limitní věta).

Wilcoxonův jednovýběrový test

$$a(i) = i, \quad S^+ = \sum_{i=1}^n \text{sign } X_i R_i^+$$

ekvivalentní vyjádření

$$S^* = \sum_{i=1, X_i > 0}^n R_i^+, \quad S^{**} = \sum_{i=1, X_i < 0}^n R_i^+$$

Platí:

$$S^+ = S^* - S^{**}$$

$$S^* + S^{**} \sum_{i=1}^n i = \frac{n(n+1)}{2}, \quad S^{**} = \frac{n(n+1)}{2} - S^*,$$

$$S^+ = 2S^* - \frac{n(n+1)}{2},$$

$$E S^+ = 0, \quad \text{var } S^+ = \sum_{i=1}^n i^2 = n(n+1)(2n+1)/6$$

Lze dokázat:

Věta 5 Necht X_1, \dots, X_n jsou nezávislé náhodné veličiny se spojitou distribuční funkcí F takovou, že

$$F(x) + F(-x) = 1, \quad \text{pro vs. } x \in R.$$

Pak pro $n \rightarrow \infty$

$$\sup_x |P(S^+ < x\sqrt{n(n+1)(2n+1)/6}) - \Phi(x)| \rightarrow 0$$

kde $\Phi(x)$ je hodnota distribuční funkce normovaného normálního rozdělení $N(0, 1)$.

Test:

- (i) Statistický software spočítá tzv. p -hodnotu.
- (ii) Pro malá n lze použít tabulky, napv r. v Andělovi, jsou tabelovány hodnoty $w_n(\alpha)$ takové, že

$$P(\min(S^*, S^{**}) \leq w_n(\alpha)) = \alpha$$

a hypotézu H_0 zamítáme, jestliže $\min(S^*, S^{**}) \leq w_n(\alpha)$, α je hladina testu

Příklad 10 pokusných osob mělo nezávisle na sobě a bez předchozího tréninku odhadnout, kdy od daného signálu uplyne 1 minuta.

Výsledky (v sekundách):

53, 48, 45, 55, 63, 51, 66, 56, 50, 58

H_0 : F je symetrická kolem 60, tj. $F(x - 60) + F(-(x - 60)) = 1$

odečteme 60 od každého pozorování

-7, -12, -15, -5, 3, -9, 6, -4, -10, -2

to vede na hypotézu symetrie kolem 0

spočteme Wilcoxonovu jednovýběrovou statistiku:

$$R_1^+ = 6, \quad R_2^+ = 9, \quad R_3^+ = 10, \quad R_4^+ = 11, \quad R_5^+ = 2, \quad R_6^+ = 7, \\ R_7^+ = 5, \quad R_8^+ = 3, \quad R_9^+ = 8, \quad R_{10}^+ = 1$$

$$S^* = 2+5 = 7, \quad S^{**} = \frac{10 \times 11}{2} - S^* = 48, \quad \min(S^*, S^{**}) = 7 < w_{10}(0, 05) =$$

Tedy zamítáme H_0 na hladině $\alpha = 0, 05$

Použijeme-li limitní věty:

$$|S^+| = 41 > \Phi^{-1}(0,975)\sqrt{387} = 1,96 \times 3, ???$$

Tedy i tady zamítáme.

Znaménkový test

$$S^+ = \text{sgn } X_i, \quad S^* = \text{pocet } X_i > 0, \quad S^{**} = \text{pocet } X_i < 0$$

Používá se pro test: $H_0 : \text{median} = 0$

S^* má binomické rozdělení $(n, P(X_i > 0))$, jsou-li X_1, \dots, X_n nezávislé stejně rozdělené náhodné veličiny

$$H_0 : P(X_i > 0) = 1/2$$

H_0 zamítáme, jestliže

$$S^* \leq k_1, \quad S^{**} \geq n - k_1$$

kde

$$P_{H_0}(S^* \leq k_1) \leq \alpha/2, \quad P_{H_0}(S^* \geq n - k_1) \leq \alpha/2$$

Je-li n velké, má $2(S^* - n/2)/\sqrt{n}$ má přibližně $N(0, 1)$ a tedy H_0 zamítáme, jestliže

$$|2S^* - n|/\sqrt{n} \geq \Phi^{-1}(1 - \alpha/2)$$

Outline

- 1 Úvod, struktura přednášky
- 2 I. Opakování základních pojmů
- 3 II. Pořadové testy
- 4 II.2. Pořadová statistiky pro test hypotézy symetrie
- 5 II.3. Dvouvýběrový problém

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

II.3. Dvouvýběrový problém

X_1, \dots, X_{n_1} jsou nezávislé stejně rozdělené náhodné veličiny se spojitou distribuční funkcí F

Y_1, \dots, Y_{n_2} jsou nezávislé stejně rozdělené náhodné veličiny se spojitou distribuční funkcí G

všechny náhodné veličiny nezávislé

$$H_0 : F = G \quad H_1 : F \neq G$$

$R_1, \dots, R_{n_1+n_2}$ jsou pořadí odpovídající $X_1, \dots, X_{n_1}, Y_1, \dots, Y_{n_2}$

Používají se testové statistiky:

$$S_1 = \sum_{i=1}^{n_1} a(R_i), \quad S_2 = \sum_{i=n_1+1}^{n_2+n_1} a(R_i)$$

Zřejmě

$$S_1 + S_2 = \sum_{i=1}^{n_1+n_2} a(i)$$

Nejčastěji se používá *Wilcoxonův dvouvýběrový test*:

$$a(i) = i, \quad i = 1, \dots, n_1 + n_2$$

$$\text{Pak } S_1 + S_2 = \sum_{i=1}^{n_1+n_2} i = \frac{(n_1+n_2)(n_1+n_2+1)}{2}$$

$$E S_1 = (n_1 + n_2 + 1)n_1/2, \quad \text{var } S_1 = (n_1 + n_2 + 1)n_1 n_2/12$$

Častěji se používá tvar:

$$U_1 = n_1 n_2 + n_1(n_1 + 1)/2 - S_1, \quad U_2 = n_1 n_2 + n_2(n_2 + 1)/2 - S_2$$

$$U_1 + U_2 = n_1 n_2, \quad E U_1 = E U_2 = n_1 n_2/2$$

U_1 je též známo jako Mann-Whitney test

Test pro malé n_1, n_2 existují tabulky, běžný software poskytuje p hodnotu, pro n_1, n_2 velká lze použít aproximaci:

$$\sup_x |P_{H_0} \left(U_1 - E_{H_0} U_1 \leq x \sqrt{\text{var } U_1} \right) - \Phi(x)| \rightarrow 0$$

pro $\min(n_1, n_2) \rightarrow \infty$

Příklad Je třeba zjistit, zda jsou dva druhy hnojení ekvivalentní při stejných ostatních podmínkách.

1. skupina (X_i) 5,7 5,5 4,3 5,9 5,2 5,6 5,8 5,1

2. skupina (Y_i) 5,0 4,5 4,2 5,4 4,4

t-test:

$$n_1 = 8, \quad \bar{X} = 5,3875, \quad s_x^2 = 0,2698$$

$$n_2 = 5, \quad \bar{Y} = 4,7000, \quad s_y^2 = 0,24$$

$t = 2,370 > t_{11}(0,975) = 2,160$ -tedy zamítáme na hladině

$\alpha = 0,05$, ovšem musí být splněny předpoklady!!!

pořadí v sech pozorování: 11, 9, 2, 13, 7, 10, 12, 6, 5, 4, 2, 8, 3

$$S_1 = 70, \quad S_2 = 21, \quad U_1 = 6, \quad U_2 = 34$$

zamítáme

$$\frac{|U_1 - E U_1|}{\sqrt{\text{var } U_1}} = 2.049 > 1.96 = \Phi^{-1}(0,975)$$

Závěrečné poznámky k základním pořadovým testům

- (a) výhody pořadových testů: rozdělení testových statistik při H_0 nezávisí na distribuční funkci náhodných veličin, výpočetně jednoduché
- (b) nevýhoda: ztrácíme část informace, vhodné jen pro jednoduché situace
- (c) existují pořadové testy i pro další situace (testy nezávislosti, pro regresní modely)
- (d) existují odhady založené na pořadích
- (e) existuje teorie týkající se volby a, známe-li distribuční funkci F
- (f) pozor na tzv. shody, jestliže se dvě pozorování shodují.

Kolmogorovy-Smirnovovy testy

X_1, \dots, X_n jsou nezávislé stejně rozdělené náhodné veličiny s spojitou distribuční funkcí F

empirická distribuční funkce F_n je definována:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n I\{X_i \leq x\} = \frac{1}{n} \text{pocet } X_i \leq x, \quad x \in R$$

Platí:

$$P(\sup_x |F_n(x) - F(x)| \geq \varepsilon) \rightarrow 0, \quad n \rightarrow \infty$$

pro každé $\varepsilon > 0$

Lze využít pro konstrukci testů:

(i) X_1, \dots, X_n jsou nezávislé stejně rozdělené náhodné veličiny se spojitou distribuční funkcí F a testujeme hypotézu:

$$H_0 : F = F_0 \quad (F_0 - \text{dano}) \quad H_1 : F \neq F_0$$

Test:

$$\sup_x |F_n(x) - F(x)| \sqrt{n} \geq q_n(1 - \alpha)$$

$q_n(1 - \alpha)$ určeno tak, aby test měl hladinu α , pro malá n existují tabulky, pro velká se používá limitní rozdělení. Statistický software spočítá p - hodnotu.

Outline

Úvod,
struktura
přednášky

I. Opakování
základních
pojmů

II. Pořadové
testy

II.2. Pořadová
statistiky pro
test hypotézy
symetrie

II.3.
Dvouvýběrový
problém

Existuje i verze, kde v H_0 je místo F_0 množina distribučních funkcí, statistický software existuje i pro tuto variantu.

(ii) *Dvouvýběrový Kolmogorovův-Smirnovův test*

X_1, \dots, X_{n_1} jsou nezávislé stejně rozdělené náhodné veličiny se spojitou distribuční funkcí F

Y_1, \dots, Y_{n_2} jsou nezávislé stejně rozdělené náhodné veličiny se spojitou distribuční funkcí G

všechny náhodné veličiny nezávislé

$$H_0 : F_1 = F_2, \quad F_1 \neq F_2$$

Test

$$\sup_x |F_{n_1}(x) - G_{n_2}(x)| \sqrt{n} \geq q_{n_1, n_2}(1 - \alpha)$$

$q_{n_1, n_2}(1 - \alpha)$ určeno tak, aby test měl hladinu α , pro malá n_1 a n_2 existují tabulky, pro velká se používá limitní rozdělení. Statistický software spočítá p - hodnotu.