

Statistika

(MD360P03Z, MD360P03U)

ak. rok 2007/2008

Karel Zvára

karel.zvara@mff.cuni.cz

http://www.karlin.mff.cuni.cz/~zvára

(naposledy upraveno 26. listopadu 2007)



Statistika (MD360P03Z, MD360P03U) ak. rok 2007/2008

příklad: potraty na 1000 obyv. (Čechy vers. Morava)

v roce 2003

kraj	Pha	Stč	Jč	PI	KV	Ús	Lb
potratovost	4,03	4,02	4,11	4,70	5,65	5,80	4,98
pořadí	7	6	8	10	12	13	11
kraj	HK	Par	Vys	JM	OI	ZI	MS
potratovost	4,33	3,38	3,57	3,70	3,65	3,42	3,87
pořadí	9	1		4	3	2	5

- ▶ H_0 : shoda populací (zejm. mediánů), H_1 : neshoda
- ▶ nejasné, kam patří kraj Vysočina; vynecháme jej
- ▶ průměrné pořadí českých krajů: $77/9=8,56$
 $W_1=7+6+8+10+12+13+11+9+1=77$
- ▶ průměrné pořadí moravských krajů: $14/4=3,5$
 $W_2=4+3+2+5=14$

Mannův-Whitneyův (Wilcoxonův) test

pořadová obdoba dvouvýběrového t -testu

- ▶ porovnáváme stejný kvantitativní znak ve dvou populacích
- ▶ máme dva **nezávislé** výběry z těchto populací
- ▶ co když nelze předpokládat normální rozdělení?
- ▶ necht' X_1, \dots, X_{n_1} a Y_1, \dots, Y_{n_2} jsou **nezávislé** výběry ze spojitého rozdělení (například věk matek, střední délka života mužů při narození ve dvou skupinách zemí, potratovost ...)
- ▶ H_0 tvrdí, že obě rozdělení jsou stejná (mezi populacemi není rozdíl, zpravidla nás zajímá, že není rozdíl v mírách polohy)
- ▶ speciálně to znamená, že **populační mediány** jsou shodné
- ▶ postup založen na pořadí bez ohledu na výběr
- ▶ idea: kdyby nebyl mezi populacemi rozdíl, byla by takto zjištěná průměrná pořadí v obou výběrech podobná

přibližné rozhodování (n_1, n_2 desítky)

- ▶ W_1, W_2 součty pořadí, W_1 standardizujeme

$$Z = \frac{W_1 - n_1(n_1 + n_2 + 1)/2}{\sqrt{n_1 n_2 (n_1 + n_2 + 1)/12}}$$

- ▶ za hypotézy (není rozdíl mezi populacemi) je použitím centrální limitní věty $Z \sim N(0, 1)$
- ▶ hypotézu zamítáme, je-li $|Z| \geq z(\alpha/2)$
- ▶ náš příklad: [wilcox.test(potr~Cechy)]

$$Z = \left| \frac{77 - 9 \cdot 14/2}{\sqrt{9 \cdot 4 \cdot 14/12}} \right| = 2,16 > 1,96 = z(0,05/2) \quad p = 3,1 \%$$

- ▶ na 5% hladině jsme prokázali rozdíl

přesný výpočet p-hodnoty Wilcoxonova testu

- ▶ zajímá nás, nakolik je náš výsledek ($W_1 = 77, W_2 = 14$) výjimečný
- ▶ máme celkem $n_1 + n_2 = 13$ pozorování, čtyři z nich (tolik jich je v menší skupině, z Moravy) lze vybrat celkem $\binom{13}{4} = 715$ způsoby
- ▶ kolik z těchto způsobů vede k tak extrémně nestejným průměrným pořadím?
- ▶ budeme hledat, kolik čtveřic označených za moravské by dalo v součtu nejvýš 14, jak nám doopravdy vyšlo
- ▶ vždy platí $W_1 + W_2 = (n_1 + n_2)(n_1 + n_2 + 1)/2 = 91$ (součet čísel $1 + 2 + \dots + n_1 + n_2$)
- ▶ stačí zabývat se jedinou ze statistik W_1, W_2 , zpravidla tou pro menší výběr

přehled možných čtveřic v nichž je součet pořadí nejvýš 14 (čtveřice vybíráme z čísel 1, 2, ..., 13)

1	1	1	1	1	1	1	1	1	1	1	2	1	1
2	2	2	2	2	2	3	2	2	2	3	3	2	2
3	3	3	4	3	4	4	3	4	5	4	4	3	4
4	5	6	5	7	6	5	8	7	6	6	5	9	8
10	11	12	12	13	13	13	14	14	14	14	14	15	15



- ▶ nejvýš 14 mohl být součet pořadí za platnosti hypotézy s pravděpodobností $p_1 = 12/715 = 0,01678$
- ▶ protože máme oboustrannou alternativu, musíme vzít v úvahu také situaci, kdy by byla na Moravě velká pořadí, p-hodnotu nutno zdvojnásobit: $p = 24/715 = 3,4 \%$

příklad: klesá potratovost? (párový t-test zde nevhodný) potratů na 100 těhotenství

Y_i	Z_i	X_i	R_i^+
24,7	23,1	1,6	4
25,7	23,6	2,1	6
31,6	27,9	3,7	12
24,3	22,2	2,1	7
26,8	23,4	3,4	11
30,6	27,9	2,7	10
21,1	21,5	-0,4	1
23,5	26,0	-2,5	8
26,9	24,3	2,6	9
22,5	23,9	-1,4	3
23,1	21,2	1,9	5
24,9	25,7	-0,8	2

- ▶ použijeme údaje z 12 okresů v letech 2000 (Y_i) a 2001 (Z_i)
- ▶ hypotéza H_0 : v obou letech potratovost stejná, rozdíly dány náhodným kolísáním; H_1 : potratovost klesá (jednostranná alt.)
- ▶ za H_0 by rozdíly měly kolísat **symetricky kolem nuly**
- ▶ za H_1 by měly převládat kladné rozdíly, spíše velké
- ▶ průměrné pořadí z 8 kladných rozdílů: 8 (součet $W = 64$), průměrné pořadí ze 4 záporných rozdílů 3,5 (součet 14)

příklad: klesá potratovost?



párový Wilcoxonův (Wilcoxon signed rank) test

- ▶ necht' $(Y_1, Z_1) \dots, (Y_n, Z_n)$ **nezávislé** dvojice, rozdíly $X_i = Y_i - Z_i$ mají **spojité** rozdělení
- ▶ H_0 : Y_i, Z_i mají stejné rozdělení (populace jsou stejné)
- ▶ mají-li Y_i, Z_i stejné rozdělení, pak rozdíly $X_i = Y_i - Z_i$ jsou symetricky rozděleny kolem nuly
- ▶ postup
 - ▶ vyloučit nulové hodnoty X_i (tedy shodné hodnoty Y_i, Z_i), podle toho případně zmenšit n
 - ▶ určit pořadí R_i^+ **absolutních hodnot** $|X_i| = |Y_i - Z_i|$
 - ▶ určit W , tj. součet pořadí původně kladných hodnot X_i
 - ▶ podle W rozhodnout

poznámky k výpočtu

- ▶ nezapomenout vyloučit nulové rozdíly
- ▶ shodným absolutním hodnotám rozdílům přiřadíme jejich průměrné pořadí
- ▶ Excel nám v takovém případě moc nepomůže, protože řeší problém shod nestandardně, např.:

X_i	4	-2	5	2	-6	-4	2	7
$ X_i $	4	2	5	2	6	4	2	7
R_i^+	4,5	2	6	2	7	4,5	2	8
Excel	4	1	6	1	7	4	1	8

- ▶ v tabulce patrné nestandardní chování Excelu
- ▶ `[wilcox.test(pokles,alternative="greater")]`

rozhodování

- ▶ na základě centrální limitní věty lze použít

$$Z = \frac{W - E W}{S.E.(W)} = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ hypotézu o shodě zamítneme, bude-li $|Z| \geq z(\alpha/2)$
- ▶ při jednostranné alternativě porovnat Z a $z(\alpha)$
- ▶ pro malý počet dvojic (do deseti) raději použít tabulky
- ▶ příklad ($W = 64, n = 12$, jinak přesně je $p = 2,6 \%$)

$$Z = \frac{64 - 12 \cdot 13/4}{\sqrt{12 \cdot 13 \cdot 25/24}} = 1,961 > 1,645 = z(0,05), p = 2,5 \%$$

párový znaménkový (sign) test

- ▶ hodnotí pouze **počet** kladných a záporných rozdílů, nezáleží na tom, jak jsou rozdíly veliké (slabší test než Wilcoxonův)
- ▶ H_0 : Y_i, Z_i mají stejné rozdělení; za hypotézy očekáváme, že počty kladných a záporných X_i jsou podobné
- ▶ označme Y počet kladných X_i z celkem n nenulových, za hypotézy $Y \sim \text{bi}(n, 1/2)$
- ▶ přibližné rozhodování (centrální limitní věta)

$$Z = \frac{Y - n/2}{\sqrt{n/4}} = \frac{2Y - n}{\sqrt{n}}, \text{ zamítnat pro } |Z| \geq z(\alpha/2)$$

- ▶ při jednostranné alternativě porovnáme Z a $z(\alpha)$

poznámky

- ▶ pro znaménkový test není třeba znát hodnoty Y_i, Z_i , stačí vědět, která z možností $Y_i > Z_i, Y_i < Z_i, Y_i = Z_i$ nastala
- ▶ náš příklad o možném poklesu potratovosti ($n = 12, Y = 8$)

$$Z = \frac{2 \cdot 8 - 12}{\sqrt{12}} = 1,155, \quad p = P(Z > 1,155) = 0,124$$

- ▶ při malých hodnotách n (do 30) se doporučuje Yatesova korekce

$$Z_{\text{Yates}} = \frac{|2Y - n| - 1}{\sqrt{n}} \text{sign}(2Y - n)$$

- ▶ náš příklad (Yatesova korekce, jiným způsobem přesně $p = 0,194$)


$$Z = \frac{|2 \cdot 8 - 12| - 1}{\sqrt{12}} \cdot 1 = 0,866, \quad p = 1 - \Phi(0,866) = 0,193$$

prokazování závislosti spojitých veličin

- ▶ víme, že pro nezávislé X, Y je $\rho_{X,Y} = 0$
- ▶ r_{xy} je odhadem $\rho_{X,Y}$; jak daleko od nuly musí být r_{xy} , abychom na hladině α prokázali závislost X, Y ?
- ▶ za předpokladu, že X, Y mají normální rozdělení (nebo počet pozorovaných dvojic X_i, Y_i je velký), hypotézu nezávislosti zamítáme pokud je $|T| \geq t_{n-2}(\alpha)$, kde

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}$$

souvisí spolu výšky rodičů?




příklad: výšky rodičů

- ▶ pro $n = 99$ dvojic byl spočítán korelační koeficient $r = 0,205$;

$$T = \frac{0,205}{\sqrt{1-0,205^2}} \sqrt{97} = 2,07 > t_{97}(0,05) = 1,98$$

- ▶ na 5% hladině jsme závislost prokázali
- ▶ $t_{97}(0,01) = 2,63$, tudíž na 1% hladině jsme závislost neprokázali
- ▶ výška zpravidla splňuje předpoklad o normálním rozdělení
- ▶ `[cor.test(vyska.m+vyska.o,data=Kojeni)]`
`[CORREL(x;y)]` (pouze výpočet korelačního koeficientu)
- ▶ není-li normální rozdělení a nemnoho pozorování, raději použít Spearmanův korelační koeficient

příklad: výšky rodičů



příklad: alkohol a úmrtnost na cirhózu

země	spotřeba	úmrtnost	R_i	Q_i	$R_i - Q_i$
Finsko	3,9	3,6	1	3	-2
Norsko	4,2	4,3	2	5	-3
Irsko	5,6	3,4	3	2	1
Holandsko	5,7	3,7	4	4	0
Švédsko	6,0	7,2	5	7	-2
Anglie	7,2	3,0	6	1	5
Belgie	10,8	12,3	7	8	-1
Rakousko	10,9	7,0	8	6	2
SRN	12,3	23,7	9	10	-1
Itálie	15,7	23,6	10	9	1
Francie	24,7	46,1	11	11	0

$$r_s = 1 - \frac{6}{11 \cdot 120} (2^2 + 3^2 + \dots) = 0,773$$

$r = 0,956$ zdánlivě mnohem těsnější závislost!

Spearmanův korelační koeficient

- ▶ místo původních hodnot x_i, y_i používá jejich pořadí R_i, Q_i
- ▶ je to vlastně Pearsonův korelační koeficient použitý na pořadí
- ▶ výpočet lze upravit, zjednodušit na

$$r_s = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ vhodný pro nelineární monotonní **závislost**, nevadí odlehlé hodnoty
- ▶ při testování nemusí být normální rozdělení

cirhóza jater a spotřeba alkoholu

