

TESTOVÁNÍ HYPOTÉZ II: ZÁKLADNÍ METODY

Martin Dostál

Honeywell International - Aerospace Advanced Technology Europe
Masarykova Univerzita v Brně, Fakulta informatiky





**POZOR, NAŠE ZPRACOVÁNÍ TÉTO PROBLEMATIKY JE S
OHLEDEM NA PROSTOR ZNAČNĚ POVRCHNÍ. STATISTIKU JE
TŘEBA STUDOVAT VE VĚTŠÍM DETAILU.**

TRÉBNÍ SYNDROMU NE NEJŠIRÍM DETAILU.

Hypotézy a metody



- podle rozdělení pravděpodobnosti
 - parametrické (opírají se předpoklad rozdělení parametru rozdělení, typicky normálního)
 - neparametrické - nemají požadavky na rozdělení, širší aplikovatelnost znamená ale vyšší riziko chyby druhého druhu - parametrické metody jsou slabší
- podle skupin
 - nepárové
 - párové

**PRO POUŽITÍ PARAMETRICKÝCH METOD, JE TAKÉ
MOŽNOST PROVÉST TRANSFORMACI DAT**

Přehled základních metod

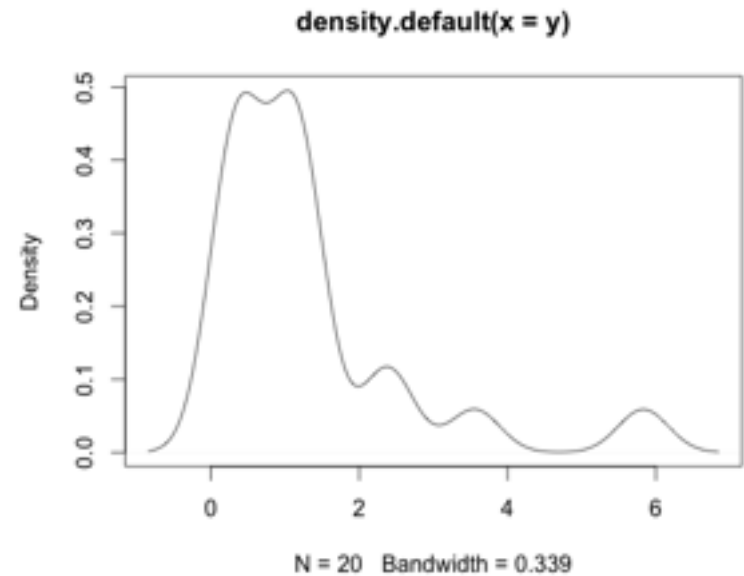

	Typ závislé proměnné		
	Intervalová/podílová data s normálním rozdělením	Intervalová/podílová data s jiným než normálním rozdělením, ordinální data	Dichotomická
Porovnání dvou nepárových skupin	Nepárový t-test	Mann-Whitneyho test	Fisherův test
Porovnání dvou párových skupin	Párový t-test	Wilcoxonův test	McNemarův test
Porovnání více než dvou nepárových skupin	Analýza rozptylu (ANOVA)	Kruskal-Wallis test	Chi-kvadrát test
Porovnání více než dvou párových skupin	Analýza rozptylu s opakovanými pozorováními (Repeated-measures ANOVA, RM-ANOVA)	Friedmanův test	Cochranův Q-test
Zjištění korelace mezi dvěma proměnnými	Pearsonův korelační koeficient	Spearmanův korelační koeficient	Cramerovo V

Test normality: QQ-plot



```
> y
 [1] 10.064251  8.101385  7.899375  6.939880  7.406208  9.663936  6.851816  8.995464
 [2]  9.333238  5.906350
 [11]  8.206650  7.262491  7.455530  7.626505  8.091334  8.964504  8.336392  8.386712
 [20]  5.635199  8.658956
> qqnorm(y)
> qqline(y)
> plot(density(y))
```

Test normality: QQ-plot



```
> y
[1] 1.2597372 1.1660276 0.3361962 0.3576890 1.3590426 0.3683438 5.8300409 0.2395507
1.1538387 1.2346716
[11] 3.5565921 0.6149820 2.3282096 0.3558715 0.1731463 2.4451087 0.4247259 0.9879564
1.0018932 1.0914047
> qqnorm(y)
> qqline(y)
> plot(density(y))
```

Test normality

- Shapiro-Wilkův test
- nulová hypotéza: data procházejí z normálního rozdělení
- pokud $p < \alpha$, zamítáme nulovou hypotézu

```
> x.normal<-rnorm(20, 5)
> x.normal
 [1] 5.207349 5.646124 4.588337 4.253999 4.155268 4.168005 5.667880 5.751262
 [2] 5.709069 5.671945 6.373626
 [12] 3.318484 6.218892 5.968625 5.843479 3.110242 7.374172 5.834502 4.932141
 [13] 5.174467
> y.lognormal<-rlnorm(20, meanlog = 0, sdlog = 1)
> shapiro.test(x.normal)

      Shapiro-Wilk normality test

data:  x.normal
W = 0.9506, p-value = 0.3756

> shapiro.test(y.lognormal)

      Shapiro-Wilk normality test

data:  y.lognormal
W = 0.4834, p-value = 2.258e-07
```

Test normality

- Kolmogorovův-Smirnovův test
- porovnává dva rozdělení dvou výběrů
- nulová hypotéza: oba výběry pocházejí ze stejného rozdělení pravděpodobnosti

```
> ks.test(x.normal, "pnorm", mean=mean(x.normal), sd=sd(x.normal))
```

```
One-sample Kolmogorov-Smirnov test
```

```
data: x.normal
```

```
D = 0.197, p-value = 0.3703
```

```
alternative hypothesis: two-sided
```

```
> ks.test(y.lognormal, "pnorm", mean=mean(y.lognormal), sd=sd(y.lognormal))
```

```
One-sample Kolmogorov-Smirnov test
```

```
data: y.lognormal
```

```
D = 0.3671, p-value = 0.006339
```

```
alternative hypothesis: two-sided
```


t-test

- předpoklad: výběr(y) pocházejí z normálního rozdělení
- varianty: jedno- a dvouvýběrový, nepárový, párový
- u nepárového testu se předpokládá homogenita rozptylů výběrů (použít Bartletův test)

jednovýběrový t-test

- nulová hypotéza: průměr rovná se μ
- alternativní hypotéza: nerovná/menší/větší

```
> x.normal
[1] 5.207349 5.646124 4.588337 4.253999 4.155268 4.168005 5.667880 5.751262 5.709069
5.671945 6.373626
[12] 3.318484 6.218892 5.968625 5.843479 3.110242 7.374172 5.834502 4.932141 5.174467
> t.test(x, alternative="greater", mu=5)
```

One Sample t-test

```
data: x
t = -1.877, df = 9, p-value = 0.9534
alternative hypothesis: true mean is greater than 5
95 percent confidence interval:
 3.872459      Inf
sample estimates:
mean of x
4.429556
```

jednovýběrový t-test

```
> t.test(x.normal, alternative="greater", mu=3)

One Sample t-test

data:  x.normal
t = 4.7039, df = 9, p-value = 0.000557
alternative hypothesis: true mean is greater than 3
95 percent confidence interval:
 3.872459      Inf
sample estimates:
mean of x
4.429556
```

Older age participants reported more time spent with the task ($M = 4.42$, $SD = 1.05$) than users did in general, $t(9) = 4.70$, $p < .001$

dvouvýběrový t-test

- nulová hypotéza: průměry výběrů se rovnají
- alternativní hypotéza: nerovnají/menší/větší

```
> small.button
[1] 5.2263125 3.2908618 3.4180683 3.7067978 0.5340702 3.0823482 2.2231250
3.4266038 4.9352018 2.8071005

> large.button
[1] 1.6873803 1.6217134 1.4451332 2.4695364 0.7222387 3.6875096 2.1387742
-0.4569893 1.6889108
[10] 1.2102160

> t.test(large.button,small.button,alternative="less")

Welch Two Sample t-test

data: large.button and small.button
t = -3.0427, df = 17.352, p-value = 0.003612
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
 -Inf -0.7050047
sample estimates:
mean of x mean of y
 1.621442  3.265049
```

Bartletův test

- nulová hypotéza: rozptyly se rovnají
- alternativní hypotéza: rozptyly se nerovnají

```
> bartlett.test(list(small.button, large.button))
```

```
Bartlett test of homogeneity of variances
```

```
data: list(small.button, large.button)
```

```
Bartlett's K-squared = 0.3245, df = 1, p-value = 0.5689
```

párový t-test

```
> red.button = c(19, 20, 21, 22, 23, 22, 27, 25, 27, 28)
> green.button = c(21, 22, 24, 24, 25, 25, 26, 26, 28, 32)
> t.test(green.button, red.button, alternative="greater", paired=TRUE)
```

Paired t-test

```
data: green.button and red.button
t = 4.3846, df = 9, p-value = 0.0008796
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
 1.105651      Inf
sample estimates:
mean of the differences
                1.9
```

Mann-Whitneyův/Wilcoxonův znaménkový test

- neparametrický test, pro data s jiným než normálním rozdělením
- určeno pro nepárová data
- dvě různé metody a tedy dvě různé testové statistiky, ale stejná p-hodnota
- nulová hypotéza: oba výběry mají stejné rozdělení pravděpodobnosti (tj. četnosti hodnot v obou souborech jsou stejné)
- alternativní hypotéza: výběry mají různá rozdělení pravděpodobnosti

```
> Question.Baseline <- c(2,4,3,1,2,3,3,2,3,1)
> Question.Test <- c(3,5,4,2,4,3,5,5,3,2)
>
> wilcox.test(Question.Baseline, Question.Test)
```

```
Wilcoxon rank sum test with continuity correction
```

```
data: Question.Baseline and Question.Test
```

```
W = 23, p-value = 0.03841
```

```
alternative hypothesis: true location shift is not equal to 0
```

Wilcoxonův test - párový

- nulová hypotéza: median rozdílů mezi párovými hodnotami se rovná nule
- alternativní hypotéza: median rozdílů mezi párovými hodnotami je různý od nuly

```
> wilcox.test(Question.Baseline, Question.Test,paired=T)
```

```
Wilcoxon signed rank test with continuity correction
```

```
data: Question.Baseline and Question.Test
```

```
V = 0, p-value = 0.01187
```

```
alternative hypothesis: true location shift is not equal to 0
```


No jo, ale ...

- co když máme více než dva výběry?
- co když mám více nezávislých proměnných?
- co když potřebuju studovat interakce mezi proměnnými?

Nápad

- proč nepoužít sadu t-testů pro dva výběry?
- pravděpodobnost chyby I. druhu:
 - $1 - (1 - \alpha)^n$, pro n porovnání potřebných pro srovnání výběrů po dvojicích
 - $n = k*(k-1)/2$, $k =$ počet výběrů
- pravděpodobnost chyby I. druhu rychle roste



ANOVA

- ANOVA = ANalysis Of VAriance, čili analýza rozptylu
- parametrická metoda (existují i neparametrické vairanty)
- existuje mnoho variant této metody podle struktury a podoby dat, viz další slajd
- není pokryto učebním textem „Základy statistické analýzy dat“

Druhy ANOVy

- podle faktorů
 - jednofaktorová
 - vícefaktorová
- podle efektů
 - s pevnými efekty
 - s náhodnými efekty
 - se smíšenými efekty
- podle pozorování
 - bez opakování
 - s opakováním
- podle designu skupin
 - vyvážená
 - nevyvážená

Nulová hypotéza

- nulová hypotéza: průměry výběrů se rovnají
- alternativní hypotéza: průměry výběrů se nerovnají
- pozor, alternativní hypotéza říká že alespoň dva průměry se nerovnají (nikoliv všechny navzájem!)

Princip

- Analysis of variance
- Variance, čili rozptyl
- porovnáváme dva zdroje rozptylu
 - mezi skupinami (výběry)
 - uvnitř skupin (výběrů)
- počítá se tzv. F-statistika

PROMĚNNÉ VYSVĚTLÍME

$$F = \frac{\text{rozptyl "mezi skupinami"}}{\text{rozptyl "uvnitř skupin"}}$$

$$MS_A = SS_A / df_a$$

$$MS_E = SS_E / df_e$$

$$F = MS_A / MS_E$$

Předpoklady

- výběry mají normální rozdělení (volnější pojetí: u větších vzorků je možné pracovat s určitou benevolencí)
- rozptyly výběrů se rovnají - vhodný je Bartletův test (volnější pojetí: je-li rozdíl mezi nejmenším a největším rozptylem dvojnásobný, je ještě možné toto kritérium považovat za splněné)

ANOVA a postup

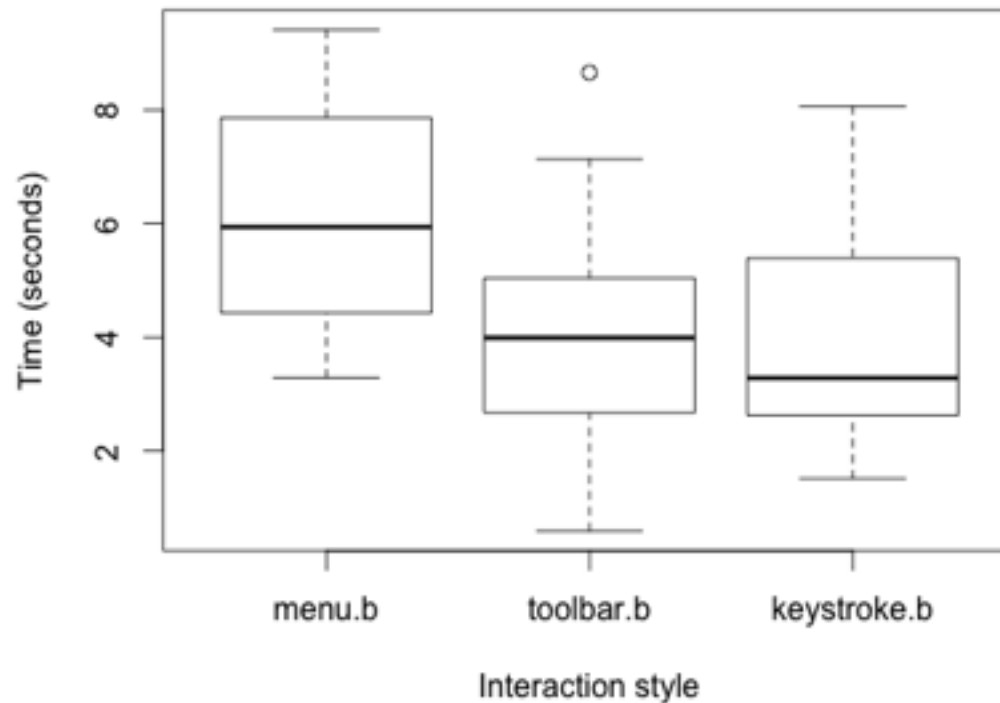
- postup je stejný jako již bylo dříve uvedeno, avšak ...
- výstupem ANOVy je informace zda zamítáme/nezamítáme nulovou hypotézu, my však potřebujeme vědět víc
- existují významné rozdíly mezi průměry výběrů, ale mezi kterými?
- pro tento účel slouží tzv. post-hoc testování

Jednofaktorová ANOVA

- jedna závislá proměnná
- jedna nezávislá proměnná
- nepárová data (design mezi skupinami)

Příklad

- data o interakci
- závislá proměnná: čas
- nezávislá proměnná: interakční styl
 - hladiny: menu, toolbar a klávesové zkratky



Příklad

```
> summary(c(menu.b, toolbar.b, keystroke.b))
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.5991	3.1750	4.3340	4.6920	6.1340	9.4000

```
> summary(menu.b)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
3.296	4.610	5.940	6.160	7.783	9.400

```
> summary(toolbar.b)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.5991	2.8170	3.9920	3.9890	5.0030	8.6530

```
> summary(keystroke.b)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
1.519	2.648	3.285	3.925	5.032	8.062

```
> bartlett.test(list(menu.b, toolbar.b, keystroke.b))
```

Bartlett test of homogeneity of variances

```
data: list(menu.b, toolbar.b, keystroke.b)
```

```
Bartlett's K-squared = 0.1961, df = 2, p-value = 0.9066
```

Příklad: ANOVA

```
> aov.b <- aov(data.full.b$time ~ data.full.b$interaction,  
data.full)  
> summary(aov.b)
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
data.full.b\$interaction	2	64.75	32.37	8.774	0.000476	***
Residuals	57	210.31	3.69			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

VARIABILITA

P-HODNOTA

HODNOTA F-STATISTIKY

Příklad: post-hoc test

- post-hoc testů existuje celá řada
- zde Tukeyho HSD test, porováváme výběry mezi sebou, nezáleží na pořadí


```
> TukeyHSD(aov.b)
```

```
Tukey multiple comparisons of means  
95% family-wise confidence level
```

```
Fit: aov(formula = data.full.b$time ~ data.full.b$interaction,  
data = data.full)
```

```
$`data.full.b$interaction`
```

	diff	lwr	upr	p adj
menu-keystroke	2.23506378	0.7733432	3.6967844	0.0014873
toolbar-keystroke	0.06418882	-1.3975318	1.5259094	0.9938631
toolbar-menu	-2.17087496	-3.6325955	-0.7091544	0.0020627



Pár poznámek k ANOVA

- nejdůležitější varianty
 - RM-ANOVA
 - vícefaktorová ANOVA
 - můžeme hledat interakce mezi nezávislými proměnnými
- v „klikacích“ aplikacích vybereme design experimentu
- v „R“ je potřeba sestavit formuli pro testování ANOVA
- pro „R“ existují alternativní knihovny pro výpočet ANOVA, zpravidla mají širší funkcionalitu a poskytují bohatší výstup potřebný pro metody následující po ANOVA, či dodatečné výpočty