

Poslední úprava dokumentu: 10. dubna 2024.

Analýza rozptylu jednoduchého třídění

Rozcvička

Představte si, že pomocí jednovýběrového t-testu testujeme hypotézu $H_0 : \mu = 3$ proti alternativě $H_1 : \mu \neq 3$. Test jsme provedli na základě 36 pozorování a vyšla nám hodnota testové statistiky $t = 1.8$. Na základě statistických tabulek (viz 7. cvičení) rozhodněte, zda H_0 zamítнout, nebo nikoli. Hladinu testu α uvažujte 5 %.

Je známo, že testová statistika Z má za platnosti H_0 normované normální rozdělení. Pro naše data nám vyšla hodnota $Z = 2.1$. Zamítneme na hladině 5 % nulovou hypotézu ve prospěch oboustranné alternativy?

1 Úvod

Připomeňte si problematiku jednoduchého třídění bud' z přednášky, nebo z textu Analýza rozptylu (dále jako *ANV*), který naleznete na mých stránkách.

Budeme pokračovat v analýze datové tabulky [Kojeni](#), s níž jsme poprvé pracovali na 4. cvičení. V pracovním listu 06 lze nalézt podrobnější popis jednotlivých proměnných.

Spusťte si [RStudio](#) a načtěte dříve uložená data [Kojeni](#). Zajistěte si přímý přístup k proměnným:

```
attach(Kojeni)
```

2 Závislost hmotnosti dítěte (ve 24. týdnu) na vzdělání matky

Pokusíme se zjistit, zda hmotnost dítěte ve 24. týdnu souvisí se vzděláním matky.

- 1) Spočtěte základní popisné statistiky pro hmotnost dítěte ve 24. týdnu ([hmotnost](#)) v závislosti na vzdělání matky ([Vzdelani](#)) a vhodně je graficky znázorněte.

```
tapply(hmotnost, Vzdelani, summary)  
boxplot(hmotnost~Vzdelani)
```

- 2) Znázorněte graficky průměrné hmotnosti v závislosti na vzdělání matky spolu s 95% intervaly spolehlivosti pro střední hmotnosti.

```
library(RcmdrMisc)  
plotMeans(hmotnost, Vzdelani, error.bars = "conf.int", level = 0.95)
```

Pravděpodobnostní model a formulace hypotéz

Označme jako Y_1 hmotnost náhodně vybraného¹ dítěte matky se základoškolským vzděláním, jako Y_2 hmotnost náhodně vybraného dítěte matky s maturitou, a jako Y_3 hmotnost náhodně vybraného

¹míněno vždy z celé populace

dítěte matky s vysokoškolským vzděláním. V případě, že lze předpokládat, že $Y_1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$, $Y_2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$, $Y_3 \sim \mathcal{N}(\mu_3, \sigma_3^2)$, a platí-li navíc $\sigma_1 = \sigma_2 = \sigma_3$, umíme pomocí analýzy rozptylu testovat $H_0 : \mu_1 = \mu_2 = \mu_3$ proti $H_1 : \mu_1 \neq \mu_2 \vee \mu_1 \neq \mu_3 \vee \mu_2 \neq \mu_3$ (kde \vee znamená „nebo“)².

Ověřování předpokladů

- 3) Normalitu rozdělení veličin Y_1, Y_2 a Y_3 budeme zkoumat až na konci.
- 4) Zjistěme si alespoň, zda je smysluplné předpokládat shodnou variabilitu hmotnosti dětí v jednotlivých skupinách matek dle jejich vzdělání. K tomu lze použít např. Leveneův test z knihovny `car`

```
install.packages("car")          # instalace knihovny (trvá dlouho)
library(car)                     # otevření knihovny
leveneTest(hmotnost ~ Vzdelani) # Leveneův test
```

nebo z knihovny `lawstat`

```
install.packages("lawstat")      # instalace knihovny (rychlejší)
library(lawstat)                # otevření knihovny
levene.test(hmotnost, Vzdelani) # Leveneův test
```

❖ Z výstupu nás zajímá pouze p-hodnota, která v tomto případě činí 0.34. Jelikož je p-hodnota větší než zvolená hladina $\alpha = 0.05$, nezamítáme shodu populačních rozptylů.

Obdobně lze použít též Bartlettův test, který je však mnohem citlivější vůči případné nenormalitě.

```
bartlett.test(hmotnost ~ Vzdelani)
```

❖ I zde nás případně zajímá pouze p-hodnota, která vyšla 0.6276. Jelikož je to hodnota vyšší než předpokládaná hladina $\alpha = 0.05$, nezamítáme shodu populačních rozptylů hmotností v jednotlivých skupinách a můžeme ji tedy předpokládat.

V praxi samozřejmě stačí použít jeden z těchto testů - bud' Leveneův, nebo Bartlettův. Vyšlo nám, že shodu populačních rozptylů hmotností v jednotlivých skupinách lze předpokládat. Označme si hodnotu tohoto společného rozptylu jako σ^2 (tj. předpokládáme $\sigma_1^2 = \sigma_2^2 = \sigma_3^2 =: \sigma^2$).

Test hypotézy

- 5) Nyní pomocí analýzy rozptylu otestujme

$$\begin{aligned} H_0 &: \mu_1 = \mu_2 = \mu_3 \quad \text{proti} \\ H_1 &: \mu_1 \neq \mu_2 \vee \mu_1 \neq \mu_3 \vee \mu_2 \neq \mu_3. \end{aligned}$$

Hladinu testu budeme uvažovat 5 %, tj. $\alpha = 0.05$.

```
mod01 <- aov(hmotnost ~ Vzdelani)    # vytvoření modelu
summary(mod01)                         # tabulka analýzy rozptylu
```

²Uvědomte si, že takto definovaná H_1 je opravdu negací H_0

	Df	Sum Sq	Mean Sq	F	value	Pr(>F)	p-hodnota
veličina určující skupiny rezidua	Vzdelani Residuals	2 96	1163768 68826778	581884 716946	0.812	0.447	

❖ vysvětlení anglických zkratek:

Df = degrees of freedom

Sum Sq = sum of squares

Mean Sq = mean squares

F value = value of F-statistics

❖ Porovnejte si tabulkou z výstupu s tabulkou z textu ANV na str. 4. Vidíme, že:

$$\text{Součet čtverců } S_A = 1163768$$

$$\text{Reziduální součet čtverců } S_e = 68826778$$

$$\text{Reziduální rozptyl } s^2 = 716946 \quad (\text{v textu ANV vzorec (2)})$$

$$\text{Hodnota testové statistiky } F = 0.812 \quad (\text{v textu ANV vzorec (3)})$$

$$\text{p-hodnota} = 0.447$$

Celková variabilita S_T v tabulce uvedena není, nebot' je součtem S_A a S_e .

❖ Jaký je závěr (zamítáme/nezamítáme H_0 na požadované hladině)?

P-hodnota vyšla 0.447, což je víc než zvolená hladina 0.05, tudíž nulovou hypotézu nezamítáme.

❖ Jak byste formulovali svůj závěr bez použití výrazů „zamítáme/nezamítáme H_0 “?

Data neprokázala, že by se hmotnost dětí ve 24. týdnu lišila v závislosti na vzdělání matky.

❖ Jaký je odhad společného rozptylu hmotností σ^2 ?

Tím odhadem je reziduální rozptyl $s^2 = \frac{S_e}{f_e} = 716946$.

- 6) V případě, kdy je nulová hypotéza zamítнутa, potřebujeme zjistit, u kterých skupin se populační průměry liší. K tomu slouží mnohonásobné porovnávání, které se většinou provádí Tukeyho metodou. V našem příkladu jsme rovnost populačních průměrů hmotností v jednotlivých skupinách nezamítli, takže mnohonásobné porovnávání zde nemá velký smysl. Pojd'me se na něj ale podívat aspoň ze cvičných důvodů.

TukeyHSD(mod01)

mnohonásobné porovnání

Tukey multiple comparisons of means 95% family-wise confidence level						
	Fit: aov(formula = hmotnost ~ Vzdelani)	rozdíl výběrových průměrů	95% interval spolehlivosti pro rozdíl populačních průměrů			
\$Vzdelani		diff	lwr	upr	p adj	
porovnání skupin "maturita" a "základní"	maturita-zakladni	-92.41427	-546.2355	361.4070	0.8786863	p-hodnota testu nulovosti rozdílu populačních průměrů
	VS-zakladni	206.33987	-381.2262	793.9059	0.6816559	
	VS-maturita	298.75414	-259.9762	857.4844	0.4138853	

❖ Z dřívějška máme označeno, že μ_1 je populační průměr hmotností dětí u matek se ZŠ. Označme si dále \bar{y}_1 výběrový průměr hmotností dětí od matek se ZŠ v našich datech. Analogicky pak budeme mít μ_2 = populační průměr hmotností dětí u matek se SŠ a \bar{y}_2 příslušný výběrový průměr. A nakonec μ_3 je populační průměr hmotností dětí u matek s VŠ a \bar{y}_3 příslušný výběrový průměr. Z výstupu výše vidíme, že:

- $\bar{y}_2 - \bar{y}_1 = -92.41427$
- 95% interval spolehlivosti pro $\mu_2 - \mu_1$ je $(-546.24, 361.41)$
- p-hodnota testu hypotézy $H_0 : \mu_2 = \mu_1$ je 0.8787

Analogicky pro ostatní dvojice. Všechny intervaly spolehlivosti obsahují nulu, tedy u porovnání všech dvojic má nula šanci být skutečným rozdílem příslušných populačních průměrů. Stejně tak všechny p-hodnoty jsou větší než 0.05.

❖ Zkratka p adj by se dala přečíst jako „p-value **adjusted** for multiple comparisons“ a upozorňuje na fakt, že p-hodnoty berou v potaz, kolik průměrů porovnáváme. Zohledňují to i intervaly spolehlivosti. Spolehlivost 95 % se vztahuje na všechny intervaly současně!

❖ Kdyby měla některá dvojice skupin populační průměry odlišné, poznaly bychom to tak, že příslušný interval spolehlivosti by neobsahoval 0 a p-hodnota by byla menší než 0.05.

❖ Intervaly spolehlivosti lze přehledně znázornit v obrázku, kde je ihned vidět, které z nich neobsahují nulu, a tudíž které z nich způsobily zamítnutí nulové hypotézy:

`plot(TukeyHSD(mod01))`

Zde všechny intervaly nulu obsahují, což je v souladu s tím, že nulová hypotéza $H_0 : \mu_1 = \mu_2 = \mu_3$ nebyla zamítnuta.

7) Normální rozdělení lze nyní ověřit „najednou“ pomocí *standardizovaných reziduí* z odhadnutého „modelu“ (viz text ANV, str. 4, dole):

`shapiro.test(rstandard(mod01))`

P-hodnota vyšla 0.7055, což je více než hladina 0.05, a tudíž normální rozdělení hmotnosti v jednotlivých skupinách nezamítáme.

8) ANOVA je v podstatě dvouvýběrový t-test rozšířený na srovnání více jak dvou skupin. Obdobně jako u t-testu lze vynechat předpoklad shodnosti rozptylů v jednotlivých skupinách a použít příkaz:

`oneway.test(hmotnost ~ Vzdelani)`

❖ Výstup této funkce je bohužel trochu chudší než u funkce `aov` a neobsahuje kompletní tabulkou analýzy rozptylu.

```
One-way analysis of means (not assuming equal variances)

data: hmotnost and Vzdelani
F = 0.98266, num df = 2.000, denom df = 48.235, p-value = 0.3817 — p-hodnota

hodnota testové      první stupně volnosti      druhé stupně volnosti
statistiky F          (odpovídají čitateli,      (odpovídají jmenovateli,
                      proto "numerator      proto "denominator
                      degrees of freedom")   degrees of freedom")
```

❖ P-hodnota testu hypotézy, že populační průměry jsou ve všech skupinách stejné, vyšla 0.3817, což je podobná hodnota jako u ANOVY s předpokladem shodných rozptylů. Náš závěr by byl tedy stejný.

- 9) Pojd'me si cvičně zkusit rozhodnout o platnosti H_0 pouze na základě testové statistiky a kvantilu F -rozdělení nalezeného v tabulkách (viz text ANV, vzorec (4)). Tabulky jsou k dispozici např. na mých stránkách k 7. cvičení.
- hodnota testové statistiky (u ANOVy pro shodné rozptyly) vyšla $F = 0.812$
 - stupně volnosti jsou $f_A = 2$ a $f_e = 96$
 - Nyní potřebujeme najít hodnotu 95% kvantilu rozdělení F_{f_A, f_e} , tj. potřebujeme $qF_{2,96}(0.95)$, který bude představovat kritickou hodnotu pro zamítnutí. V tabulkách na mých stránkách jsou kvantily $qF_{k,n}(1 - \alpha)$ značené jakožto kritické hodnoty $F_{k,n}(\alpha)$.
 - Bohužel v těchto tabulkách není možné zvolit druhý stupeň volnosti $n = 96$. Vezmeme tedy nejbližší ($n = 100$) a dostáváme $F_{2,100}(0.05) = 3.09$. Skutečný kvantil bychom mohli zjistit v R jakožto
- $qf(0.95, 2, 96)$
- a dozvěděli bychom se, že je to 3.091191.
- Tak jako tak hodnota testové statistiky nepřekročila kritickou hodnotu v podobě kvantilu, a tudíž bychom dospěli ke stejnemu závěru - nezamítnout H_0 .

3 Závislost výšky otce na vzdělání matky



Pokuste se zjistit, zda výška otce závisí na vzdělání matky. Jestliže zjistíte významnou závislost, jak se projevuje? Hladinu testování zvolte 5 %.

Označme si opět jako Y_1 výšku otce náhodně vybraného dítěte matky se základoškolským vzděláním, jako Y_2 výšku otce náhodně vybraného dítěte matky s maturitou, a jako Y_3 výšku otce náhodně vybraného dítěte matky s vysokoškolským vzděláním. Budeme předpokládat, že $Y_1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$, $Y_2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$, $Y_3 \sim \mathcal{N}(\mu_3, \sigma_3^2)$, a že platí-li navíc $\sigma_1 = \sigma_2 = \sigma_3$. Tyto předpoklady samozřejmě pro naše data ověříme. Pomocí analýzy rozptylu pak otestujeme hypotézu $H_0 : \mu_1 = \mu_2 = \mu_3$ proti $H_1 : \mu_1 \neq \mu_2 \vee \mu_1 \neq \mu_3 \vee \mu_2 \neq \mu_3$ (kde \vee znamená „nebo“).

- 1) Základní popisné statistiky.

```
tapply(vyska.o, Vzdelani, summary)
```

- 2) Popisné obrázky.

```
plot(vyska.o ~ Vzdelani, ylab="Vyska otce (cm)")      # krabicové grafy
plot_of_means(vyska.o, Vzdelani, "ci", prob=0.95)       # graf průměrů
```

- 3) Leveneův test homoskedasticity.

```
leveneTest(vyska.o ~ Vzdelani)    # nebo:
levene.test(vyska.o, Vzdelani)
```

❖ P-hodnota je 0.8092, tudíž shodu populačních rozptylů nezamítáme. Označme si tuto společnou hodnotu populačního rozptylu jako σ^2 (předpokládáme tedy $\sigma_1^2 = \sigma_2^2 = \sigma_3^2 =: \sigma^2$).

- 4) ANOVA (při předpokladu shodných rozptylů).

```
mod02 <- aov(vyska.o ~ Vzdelani)    # vytvoření modelu
summary(mod02)                      # tabulka analýzy rozptylu
```

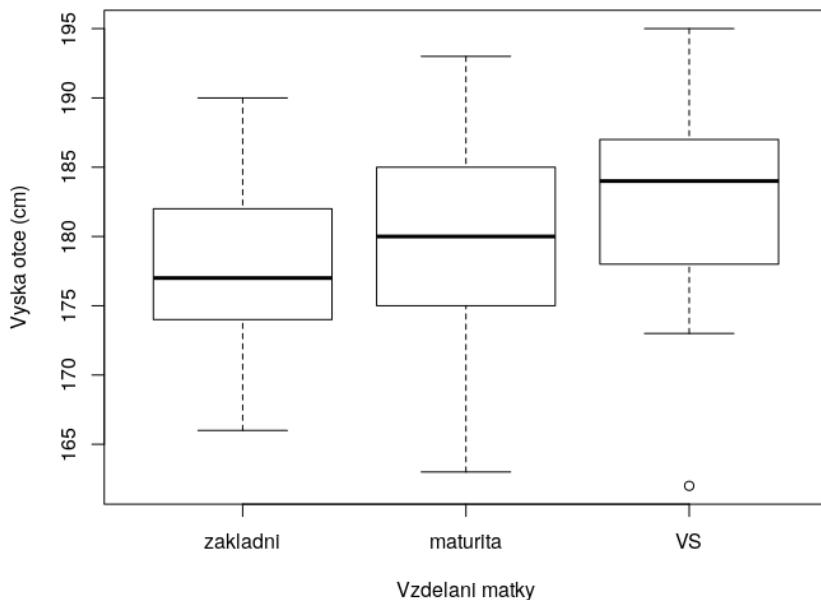
❖ P-hodnota vyšla 0.0137, což je menší než zvolená hladina $\alpha = 0.05$. Zamítáme tedy nulovou hypotézu. Na 5% hladině jsme prokázali, že populační průměry výšky otců se liší pro různá vzdělání matky. Mezi některými skupinami je statisticky významný rozdíl.

❖ Odhad společného rozptylu výšky otců σ^2 je reziduální rozptyl $s^2 = \frac{S_e}{f_e} = 42.97$.

- 5) Dále by nás zajímalo, které dvě skupiny se liší natolik, že došlo k zamítnutí. Mnohonásobné porovnání provedeme opět pomocí Tukeyho metody.

```
TukeyHSD(mod02)
plot(TukeyHSD(mod02))
```

- ❖ Z p-hodnot (a také z intervalů spolehlivosti) vidíme, že významně se liší skupiny „VŠ“ a „základní“. Příslušný interval spolehlivosti pro $\mu_3 - \mu_1$ totiž neobsahuje nulu a také p-hodnota testu $H_0 : \mu_3 = \mu_1$ je menší než 0.05.
- ❖ Už z pohledu na krabicové grafy je patrné, že skupina „VŠ“ a „základní“ mají mezi sebou největší rozdíl ve výškách otců. Dvojice „VŠ“-„maturita“ nebo „maturita“-„základní“ se samozřejmě taky trochu liší, ale ne natolik, aby to vyšlo statisticky významné.



- 6) Test normality se standardizovanými rezidui z ANOVY.

```
shapiro.test(rstandard(mod02))
```

- ❖ Je to dobré, p-hodnota vyšla 0.346, tedy větší než hladina testu 0.05, takže normalitu rozdělení výšek otců můžeme ve všech třech skupinách předpokládat. Použití standardní analýzy rozptylu tedy bylo oprávněné.

4 Závislost věku otce na vzdělání matky

Pokuste se zjistit, zda věk otce závisí na vzdělání matky. Hladinu testu uvažujme opět 5 %.

Nejprve si opět zavedeme náš pravděpodobnostní model, abychom slovní zadání převedli do řeči matematiky.

Označme si opět jako Y_1 věk otce náhodně vybraného dítěte matky se základoškolským vzděláním, jako Y_2 věk otce náhodně vybraného dítěte matky s maturitou, a jako Y_3 věk otce náhodně vybraného dítěte matky s vysokoškolským vzděláním. Chceme otestovat hypotézu $H_0 : \mu_1 = \mu_2 = \mu_3$

proti $H_1 : \mu_1 \neq \mu_2 \vee \mu_1 \neq \mu_3 \vee \mu_2 \neq \mu_3$ (kde \vee znamená „nebo“). Pokud bychom mohli předpokládat, že $Y_1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$, $Y_2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$, $Y_3 \sim \mathcal{N}(\mu_3, \sigma_3^2)$, mohli bychom použít analýzu rozptylu.

1) Základní popisné statistiky.

```
tapply(vek.o, Vzdelani, summary)
```

2) Popisné obrázky.

```
plot(vek.o ~ Vzdelani, ylab="Vek otce")
plot_of_means(vek.o, Vzdelani, "ci", prob=0.95) # graf průměrů s 95% intervaly
# spolehlivosti
```

3) Leveneův test homoskedasticity.

```
leveneTest(vek.o ~ Vzdelani)
```

❖ P-hodnota vyšla 0.1077, tedy nezamítáme shodu rozptylů věku otců v jednotlivých skupinách.

4) ANOVA (při předpokladu shodných rozptylů).

```
mod03 <- aov(vek.o ~ Vzdelani)
summary(mod03)
```

5) Test normality se standardizovanými reziduji z ANOVy.

```
shapiro.test(rstandard(mod03))
```

P-hodnota Shapiro.Wilkova testu vyšla 0.001746. Zjištujeme tedy, že rozdělení reziduů v ANOVA modelu je významně nenormální. V tom případě byla celá předchozí analýza zbytečná a můžeme ji zahodit. Budeme se muset uchýlit k nějakému neparametrickému (pořadovému) testu.

V případě dvouvýběrového t-testu jsme alternativně používali neparametrický Wilcoxonův (Mannův-Whitneyův) test. V případě srovnání více jak dvou skupin je neparametrickou obdobou ANOVy Kruskalův-Wallisův test.

Otestujme tedy pomocí Kruskalova-Wallisova testu významnost závislosti věku otce na vzdělání matky. Musíme si ale přeformulovat tvar hypotéz, aby odpovídala tomuto testu:

H_0 : rozdělení věku otců je ve všech skupinách vzdělání matky shodné (tj. jsou shodné i střední hodnoty)
 H_1 : rozdělení věku otců se liší pro různé skupiny vzdělání matky

❖ v R provedeme Kruskalův-Wallisův test pomocí příkazu

```
kruskal.test(vek.o ~ Vzdelani)
```

Kruskal-Wallis rank sum test

```
data: vek.o by Vzdelani
Kruskal-Wallis chi-squared = 11.888, df = 2, p-value = 0.002621
```

hodnota testové statistiky
(v textu ANV vzorec (7))

stupně volnosti
(počet skupin míinus 1)

❖ Jaký je závěr?

Vidíme, že p-hodnota je menší než uvažovaná hladina 0.05. Na hladině 5 % jsme tedy prokázali, že rozdílení věku otců se liší pro různá vzdělání matky.

❖ Zvládli byste o platnosti H_0 rozhodnout opět pouze na základě statistických tabulek (tj. bez použití p-hodnoty)?