

Poslední úprava dokumentu: 17. dubna 2024.

## Analýza kategoriálních dat ( $\chi^2$ -testy dobré shody)

Prostudujte si základní pojmy a testy v multinomickém rozdělení a kontingenčních tabulkách. Využít můžete materiály z přednášky, nebo text *Analýza kategoriálních dat* (dále jako *AKD*), který najdete na mých stránkách.

### 1 Shoda s multinomickým rozdělením

Rozhodněte, zda četnosti 95, 169, 89 odpovídají ideálnímu genotypovému štěpnému poměru 1:2:1. Hladinu testu uvažuje 5 %.

Vektor  $(Y_1, Y_2, Y_3)$  představující četnosti jednotlivých genotypů ve skupině  $n$  jedinců má multinomické rozdělení s parametry  $n, \pi_1, \pi_2, \pi_3$ . Formálně zapsáno:  $(Y_1, Y_2, Y_3) \sim M(n, (\pi_1, \pi_2, \pi_3))$ . My jsme celkem zkoumali  $n = 95 + 169 + 89 = 353$  jedinců a naměřili jsme četnosti  $n_1 = 95, n_2 = 169, n_3 = 89$ .

Nyní bychom rádi otestovali hypotézu, zda tyto četnosti odpovídají teoretickému poměru 1 : 2 : 1, to jest, jestli se jednotlivé genotypy realizují s pravděpodobnostmi  $\frac{1}{4}, \frac{1}{2}, \frac{1}{4}$ . Chceme testovat hypotézu:

$$H_0 : (\pi_1, \pi_2, \pi_3) = \left( \frac{1}{4}, \frac{1}{2}, \frac{1}{4} \right)$$

proti:  $H_1 : (\pi_1, \pi_2, \pi_3) \neq \left( \frac{1}{4}, \frac{1}{2}, \frac{1}{4} \right)$ .

1) K testu samozřejmě použijeme  $\chi^2$  test dobré shody (viz text *AKD*, sekce 1.1):

```
(cetnosti <- c(95, 169, 89))      # pozorovane cetnosti
(prpsti <- c(1, 2, 1)/4)         # hypoteticke pravdepodobnosti
chisq.test(cetnosti, p=prpsti)   # test dobre shody
```

✧ Z výstupu se dozvídáme, že:

- hodnota testové statistiky je  $X^2 = 0.84136$  (viz *AKD*, vzorec (6))
- $df = 2$  (počet stupňů volnosti je  $k - 1 = 3 - 1 = 2$ , přičemž  $k =$  počet kategorií)
- p-hodnota = 0.6566

✧ Jaký je závěr?

P-hodnota je větší než zvolená hladina 0.05, nezamítáme tedy nulovou hypotézu, že četnosti jednotlivých genotypů odpovídají teoretickému poměru 1:2:1.

✧ Jak byste o nulové hypotéze rozhodli v případě, kdy byste měli k dispozici pouze hodnotu testové statistiky a statistické tabulky?

Kritickou hodnotu tohoto testu najdeme v tabulkách (viz např. materiály k 8. cvičení), kde je označena jako  $\chi_n^2(\alpha) = \chi_2^2(0.05) = 5.99$ . Tato kritická hodnota je samozřejmě rovna 95% kvantilu  $\chi^2$ -rozdělení se 2 stupni volnosti, tj.  $q\chi_2^2(0.95)$ , což si lze snadno ověřit příkazem

```
qchisq(0.95,2)      # 95% kvantil chi-kvadrat rozdeleni
```

Jelikož hodnota testové statistiky 0.84136 není větší než kritická hodnota 5.99, tak nezamítáme nulovou hypotézu.

- 2) Nesmíme zapomenout, že použitý  $\chi^2$ -test dobré shody funguje dobře pouze pro dostatečně velké očekávané četnosti. Musíme tedy zkontrolovat, že všechny očekávané četnosti jsou větší nebo rovny 5.

```
(ex <- chisq.test(cetnosti, p=prpsti)$expected) # očekávané četnosti
```

✧ Jsou všechny očekávané četnosti dost velké? Ano, všechny očekávané četnosti jsou  $\geq 5$ .

- 3) Očekávané četnosti lze získat také jednoduchým příkazem:

```
(ex <- prpsti * sum(cetnosti))
```

Nicméně předchozí konstrukce se nám bude hodit i u testů dobré shody v kontingenčních tabulkách.

- 4) V rámci procvičení programování v R si můžeme zkusit testovou statistiku a p-hodnotu spočítat „ručně“:

```
(Xs <- (cetnosti - ex)^2 / ex) # komponenty testové statistiky  
(X <- sum(Xs)) # testová statistika  
1 - pchisq(X, df=2) # p-hodnota
```



- 5) Rozhodněte, zda lze považovat za reprezentativní vzorek dospělých žen, v němž je

180 žen svobodných,  
239 žen vdaných,  
75 žen rozvedených,  
4 ženy ovдовělé,

když v odpovídající věkové populaci jsou skutečné podíly žen rovny po řadě 34,27 %, 52,02 %, 12,50 % a 1,21 %.

## 2 Analýza obecné kontingenční tabulky

Uvažujme následující kontingenční tabulku, jež udává počty novomanželských párů s jednotlivými kombinacemi vzdělání ženicha a nevěsty získané v jistém období na nejmenované radnici.

Ženich	Nevěsta		
	základní	maturita	VŠ
základní	24	12	3
maturita	7	24	3
VŠ	3	9	15

### Test nezávislosti (v zadané kontingenční tabulce)

- 1) Máme tedy dva znaky:  $X$  = vzdělání nevěsty,  $Y$  = vzdělání ženicha. Jako první nás zajímá, zda jsou tyto veličiny závislé.

$H_0$  :  $X$  a  $Y$  jsou nezávislé

$H_1$  :  $X$  a  $Y$  jsou závislé

K tomuto účelu lze použít  $\chi^2$ -test nezávislosti, případně Fisherův test. Hladinu testu budeme uvažovat 5 %.

✧ Nejprve si musíme tabulku výše zadat do R:

```
TAB <- matrix(c(24,7,3, 12,24,9, 3,3,15), nrow=3) # vytvoreni matice cisel
rownames(TAB) <- c("zakladni", "maturita", "VS") # pojmenovani radku
colnames(TAB) <- c("zakladni", "maturita", "VS") # pojmenovani sloupcu
print(TAB)
```

✧ Nyní provedeme  $\chi^2$ -test nezávislosti (viz text AKD, sekce 2.1)

```
chisq.test(TAB) # chi^2 test
```

✧ Testová statistika vyšla  $X^2 = 43.219$  a p-hodnota je  $9.32 \cdot 10^{-9}$ . Jelikož je p-hodnota mnohem menší než hladina 0.05, zamítáme  $H_0$ . Na hladině 5 % jsme tedy prokázali, že vzdělání snoubenců jsou závislá.

2) Jsou všechny očekávané četnosti dostatečně velké?

```
chisq.test(TAB)$expected # ocekavane cetnosti pri nezavislosti
```

Je to jen tak tak, ale všechny očekávané četnosti v tabulce jsou  $\geq 5$ . Rozdělení  $\chi_4^2$  by tedy mělo poměrně dobře aproximovat rozdělení testové statistiky, a test by měl tudíž pro naše data fungovat dobře.

3) Kdybychom pro rozhodování měli k dispozici pouze statistické tabulky, museli bychom si najít příslušnou kritickou hodnotu. Naše tabulka má rozměry  $I \times J$ , kde  $I = J = 3$ . Víme, že testová statistika má asymptoticky  $\chi^2$  rozdělení se stupni volnosti  $df = (I - 1)(J - 1) = 2 \cdot 2 = 4$ . Najdeme si tedy kritickou hodnotu  $\chi_4^2(\alpha) = 9.49$ , která odpovídá kvantilu

```
qchisq(0.95, df=4)
```

Jelikož testová statistika  $X^2 = 43.219$  překračuje tuto kritickou hodnotu, docházíme ke stejnému závěru jako pomocí p-hodnoty, a to zamítnout nezávislost veličin.

4) Všechny očekávané četnosti v tabulce jsou sice větší než 5, ale někdy jenom těsně. Pokud bychom se v tomto případě nechtěli spoléhat na asymptotiku  $\chi^2$ -testu, můžeme použít Fisherův faktoriálový test (viz AKD, sekce 2.2), který je přesný a není založen na žádné asymptotice.

```
fisher.test(TAB) # Fisheruv test
```

✧ Tento test nepočítá hodnotu žádné testové statistiky, ale z pravděpodobnosti realizace naší konkrétní tabulky při platnosti nulové hypotézy počítá přímo p-hodnotu. Ta v tomto případě činí  $5.472 \cdot 10^{-8}$ . Je tedy menší než zvolená hladina 0.05, a docházíme tedy ke stejnému závěru jako pomocí  $\chi^2$ -testu. Na hladině 5 % zamítáme hypotézu, že vzdělání snoubenců jsou nezávislá.

## Test symetrie

5) Lze se též ptát, zda je sdružené rozdělení vzdělání ženicha a nevěsty symetrické. Použijeme-li opět naše značení  $X =$  vzdělání nevěsty,  $Y =$  vzdělání ženicha, pak symetrie rozdělení  $(X, Y)$  odpovídá testu hypotézy

$$H_0 : P(X = i \ \& \ Y = j) = P(X = j \ \& \ Y = i) \quad \text{pro všechny dvojice } (i, j)$$

$$H_1 : P(X = i \ \& \ Y = j) \neq P(X = j \ \& \ Y = i) \quad \text{pro některou dvojici } (i, j)$$

kde  $i, j = 1$  (ZŠ),  $2$  (maturita),  $3$  (VŠ). K tomu se použije Bowkerův test symetrie (viz text AKD, sekce 2.3), který je v R nazýván McNemarův:

```
mcnemar.test(TAB)
```

Hodnota testové statistiky (*AKD*, vzorec (9)) vyšla 4.3158, p-hodnota je 0.2293. Pro úplnost dodejme, že náš počet kategorií vzdělání je  $I = 3$ , a tudíž počet stupňů volnosti příslušného  $\chi^2$  rozdělení je  $I(I - 1)/2 = 3 \cdot 2/2 = 3$ , což je taktéž uvedeno ve výstupu pod označením *df* (= degrees of freedom).

✧ Jaký je závěr? Hladinu testu uvažujte 5 %.

P-hodnota je vyšší než zvolená hladina 0.05, tudíž nezamítáme, že rozdělení vzdělání snoubenců je symetrické.

✧ To, že testová statistika McNemar's chi-squared z výstupu souhlasí s teoretickým vzorcem (9) z textu *AKD* si můžeme ověřit ručním výpočtem:

$$(12-7)^2/(12+7) + (3-3)^2/(3+3) + (3-9)^2/(3+9)$$

✧ Pokud bychom neměli k dispozici p-hodnotu, ale pouze hodnotu testové statistiky, museli bychom počítat kritickou hodnotu. V tabulkách snadno najdeme, že kritická hodnota  $\chi_{I(I-1)/2}^2(\alpha) = \chi_3^2(0.05)$  je 7.81, což si lze ověřit i výpočtem odpovídajícího kvantilu  $q\chi_3^2(0.95)$

$$q\chi_{3^2}(0.95, df=3*2/2)$$

Jelikož  $Q = 4.3158 < 7.81 = \chi_3^2(0.05)$ , tedy hodnota testové statistiky nepřekročila kritickou hodnotu, nezamítáme naši nulovou hypotézu, že rozdělení vektoru  $(X, Y)$  je symetrické. (Což je tedy stejný závěr jako pomocí p-hodnoty).

## Test nezávislosti (včetně přípravy kontingenční tabulky)

Nyní se vrátíme k datům *Kojeni*. Načtěme si dříve uložená data do [RStudio](#).

```
load("Kojeni.RData")
Kojeni$fOtec <- factor(Kojeni$Otec, labels=c("ne", "ano"))
Kojeni$fDudlik <- factor(Kojeni$Dudlik, labels=c("ne", "ano"))
Kojeni$fPlan <- factor(Kojeni$Plan, labels=c("ne", "ano"))
save(Kojeni, file="Kojeni.RData")
attach(Kojeni)
```



6) Souvisí přítomnost otce u porodu (proměnná *Otec*, resp. *fOtec*) se vzděláním matky (*Vzdelani*)? To jest, jsou tyto veličiny závislé? Pokuste se sami interpretovat výsledky následujících příkazů.

```
(TAB <- table(Vzdelani, fOtec))      # kontingencni tabulka
(PTAB <- prop.table(TAB, margin=1) * 100)      # radkove proporce (v %)
chisq.test(TAB)                       # chi^2 test dobré shody
chisq.test(TAB)$expected               # ocekavane cetnosti pri nezávislosti
fisher.test(TAB)                       # Fisheruv test
```

## 3 Test nezávislosti ve čtyřpolní tabulce

Liší se podíl dětí, které dostaly dudlík (proměnná *Dudlik*, resp. *fDudlik*) mezi dětmi „plánovanými“ a „neplánovanými“ (*Plan*, resp. *fPlan*)? Jinými slovy - jsou veličiny *Dudlik* a *Plan* závislé? Na hladině  $\alpha = 0.05$  budeme testovat

$H_0$  : veličiny *Dudlik* a *Plan* jsou nezávislé  
proti  $H_1$  : veličiny *Dudlik* a *Plan* jsou závislé .

Veličiny *Dudlik* a *Plan* nabývají obě hodnot 0 (= ne) a 1 (= ano). Příslušná kontingenční tabulka má následující tvar:

		fDudlik			=			fDudlik		
		ne	ano			ne	ano			
fPlan	ne	$n_{11}$	$n_{12}$	$n_{1\cdot}$		9	32	41		
	ano	$n_{21}$	$n_{22}$	$n_{2\cdot}$		14	44	58		
		$n_{\cdot 1}$	$n_{\cdot 2}$	$n$		23	76	99		

a v R si ji snadno vytvoříme příkazem

```
(TAB <- table(fPlan, fDudlik)) # konting. tabulka
```

Pro zajímavost si můžeme spočítat i řádková procenta

```
(PTAB <- prop.table(TAB, margin=1) * 100) # radkove proporce (v %)
```

Jsou-li obě veličiny nezávislé, měly by být (v ideálním případě) oba řádky shodné.

- 1) První možností, jak přistoupit k testu nulové hypotézy o nezávislosti, je pomocí  $\chi^2$ -testu (viz text AKD, sekce 4.2).

```
chisq.test(TAB, correct=FALSE) # chi^2 test (bez Yatesovy korekce)
```

✧ Testová statistika (AKD, vzorec (15)) má hodnotu  $X^2 = 0.0644$  a příslušná p-hodnota vyšla 0.7997. Jelikož  $0.7997 > 0.05$ , tak nezamítáme nulovou hypotézu, že veličiny jsou nezávislé. Data tedy neprokázala, že by plánovanost dítěte měla nějakou souvislost s používáním dudlíku.

✧ Očekávané četnosti jsou

```
chisq.test(TAB)$expected
```

a jelikož jsou všechny větší než 5, měla by být aproximace rozdělení statistiky  $X^2$  rozdělením  $\chi_1^2$  dobrá. Tudíž použití  $\chi^2$ -testu nezávislost bylo v pořádku.

✧ Nicméně můžeme si vyzkoušet i použití  $\chi^2$ -testu s Yatesovou korekcí, která je vhodná zejména v případě malých četností:

```
chisq.test(TAB) # chi^2 test s Yatesovou korekci
```

Hodnota testové statistiky i p-hodnota se samozřejmě trochu změnila, ale náš závěr byl stejný.

- 2) Další možností je použít Fisherův faktoriálový test (viz text AKD, sekce 4.3).

```
fisher.test(TAB)
```

✧ P-hodnota vyšla 1, a tudíž ani Fisherův test nezamítá nulovou hypotézu o nezávislosti. (Ona to není úplně čistá 1, ale je to číslo tak blízké 1, že R při zaokrouhlování výstupu to již uvádí jako 1.)

✧ Fisherův faktoriálový test je spjat s pojmem **podílu šancí** (viz AKD, vzorec (16)), který má pro naši tabulku tvar

$$\beta = \frac{\text{šance nemít dudlík mezi neplánovanými dětmi}}{\text{šance nemít dudlík mezi plánovanými dětmi}} = \frac{\text{šance být neplánovaný mezi dětmi bez dudlíku}}{\text{šance být neplánovaný mezi dětmi s dudlíkem}}$$

(záleží jestli se díváme na řádky, nebo na sloupce tabulky, viz Poznámka 7 v textu AKD).

✧ Hypotézu nezávislosti lze v kontextu podílu šancí přeformulovat jako

$$H_0 : \beta = 1$$

$$H_1 : \beta \neq 1.$$

čemuž odpovídá i komentář ve výstupu funkce `fisher.test`: „alternative hypothesis: true odds ratio is not equal to 1“.

✧ Ve výstupu je dále uveden i odhad  $\beta$ , tzv. empirický podíl šancí:  $b = 0.885025$ . Není to ale přesně ten, na který jsme zvyklí (vzorec (17) v *AKD*), ten by vyšel

$$b = \frac{n_{11}n_{22}}{n_{12}n_{21}} = \frac{9 * 44}{14 * 32} = 0.8839286 \quad (1)$$

**R** odhad počítá pomocí metody maximální věrohodnosti (populární metoda pro odhad parametrů), a dostává tedy malinko odlišný výsledek.

✧ **R** dále uvádí i 95% interval spolehlivosti pro  $\beta$ , který činí (0.298, 2.518). V tomto intervalu tedy s pravděpodobností 0.95 leží skutečný podíl šancí  $\beta$ . Hodnota 1 v tomto intervalu leží, což koresponduje s naším závěrem nezamítnout nezávislost.

3) Třetí způsob jak otestovat nezávislost je pomocí porovnání dvou binomických rozdělení (viz *AKD*, sekce 4.4). Označme si jako  $\pi_0$  (populační) proporci dětí bez dudlíku mezi neplánovanými a jako  $\pi_1$  (populační) proporci dětí bez dudlíku mezi plánovanými. Děti tedy rozdělíme do dvou skupin (na plánované a neplánované) a za „úspěch“ považujeme, když neměli dudlík. Jsou-li veličiny **Dudlik** a **Plan** nezávislé, měly by být populační proporce (pravděpodobnosti „úspěchu“) stejné. Budeme tedy testovat  $H_0 : \pi_0 = \pi_1$  proti  $H_1 : \pi_0 \neq \pi_1$ .

```
(nemaDudlik <- TAB[, "ne"])           # počty deti bez dudliku
(pocetDeti <- margin.table(TAB, 1))  # počty deti neplanovanych a planovanych
prop.test(nemaDudlik, pocetDeti, correct=FALSE) # bez Yatesovy korekce
```

✧ Příkaz `prop.test` slouží k otestování rovnosti pravděpodobností dvou (i více) binomických rozdělení. Prvním argumentem jsou počty „úspěchů“ (= dětí bez dudlíku), druhým argumentem jsou počty pokusů (= dětí).

✧ Hodnota testové statistiky (viz *AKD*, vzorec (18)) vychází  $X^2 = 0.0644$ .

✧ P-hodnota je 0.7997, což je víc než zvolená hladina  $\alpha = 0.05$ . Nezamítáme tedy nulovou hypotézu o rovnosti proporcí dětí bez dudlíku v obou skupinách (dětmi plánovanými a neplánovanými). Nezamítáme tedy nezávislost veličin **Dudlik** a **Plan**.

✧ Liší se P-hodnota od  $\chi^2$ -testu nezávislosti (se stejnou nepřítomností korekce na spojitost)?

Ne, p-hodnota je shodná, neboť oba testy v principu testují totéž.

✧ Ve výstupu je dále k dispozici 95% interval spolehlivosti pro rozdíl  $\pi_0 - \pi_1$ .

Skutečný rozdíl populačních proporcí by měl tedy s pravděpodobností 0.95 ležet v intervalu (-0.1897, 0.1460). Jelikož 0 leží v tomto intervalu, má šanci být skutečnou hodnotou rozdílu  $\pi_0 - \pi_1$ , což je v souladu s naším předchozím závěrem nezamítnout hypotézu o rovnosti proporcí.

✧ Posledním údajem jsou odhady  $\pi_0$  a  $\pi_1$ , které činí:

$$\hat{\pi}_0 = \frac{n_{11}}{n_1} = \frac{9}{41} = 0.2195122$$
$$\hat{\pi}_1 = \frac{n_{21}}{n_2} = \frac{14}{58} = 0.2413793.$$

✧ Opět je k dispozici Yatesova korekce na spojitost:

```
prop.test(nemaDudlik, pocetDeti) # s Yatesovou korekci
```

P-hodnota je opět shodná jako u  $\chi^2$ -testu (s Yatesovou korekcí).

- 4) Samozřejmě by šlo si jako  $\eta_0$  označit (populační) proporci „neplánovaných“ dětí mezi těmi bez dudlíku a jako  $\eta_1$  (populační) proporci „neplánovaných“ dětí mezi těmi s dudlíkem, tj. děti bychom rozdělili do dvou skupin podle toho, jestli mají dudlík a za „úspěch“ bychom považovali, že byly neplánované. Pak bychom testovali hypotézu  $H_0 : \eta_0 = \eta_1$  proti  $H_1 : \eta_0 \neq \eta_1$ .

```
(nePlan <- TAB["ne",]) # pocty neplanovanych deti  
(pocetDeti <- margin.table(TAB, 2)) # pocty deti bez a s dudlikem  
prop.test(nePlan, pocetDeti, correct=FALSE) # bez Yatesovych korekci  
prop.test(nePlan, pocetDeti) # s Yatesovymi korekcemi
```

✧ Tento postup je zcela ekvivalentní s přístupem z bodu 3). P-hodnota vychází stejně a náš závěr je také shodný.

## 4 Konec práce

Než zavřete všechna okna, nezapomeňte si uložit poslední změny ve skriptovém souboru:

**File** ➔ **Save**

nebo klávesovou skratkou **Ctrl-s**.