

11 Hodnocení kontingenčních tabulek

Příklad 11.1. Testování hypotézy o nezávislosti, měření síly závislosti

V roce 1950 zkoumali Yule a Kendall barvu očí a vlasů u 6800 mužů. Výsledky zkoumání jsou uvedeny v následující tabulce a v souboru `vlasu_oci.csv`.

Barva očí	Barva vlasů			
	světlá	kaštanová	černá	rezavá
modrá	1768	807	189	47
šedá/zelená	946	1387	746	53
hnědá	115	438	288	16

Na asymptotické hladině významnosti $\alpha = 0.05$ testujte hypotézu o nezávislosti barvy očí a barvy vlasů. Vypočtete Cramérův koeficient.

Řešení příkladu 11.1

- H_0 : Barva očí a barva vlasů stochasticky nezávislé.
- H_1 : Barva očí a barva vlasů stochasticky nezávislé.
- Hladina významnosti $\alpha =$

Podmínka dobré aproximace

```
1 data <- read.delim(..., header = T, row.names = 1) # nacteni datoveho souboru
2 # funkce chisq.test()
3 # 1. argument ... tabulka dat
4 # correct = F ... zakaze provedeni korekce Pearsonova (viz prikklad 11.3)
5 # vystup funkce:
6 # chisq.test() ... kompletne vystupni zprava Pearsonova chi^2 testu
7 # chisq.test()$expected ... tabulka ocekavanych cetnosti
8 round(chisq.test(data, correct = F)$expected, 1) # tabulka ocekavanych cetnosti
9 # (zaokrouhlena na 1 des. misto)
```

	svetla	kastanova	cerna	rezava
modra	1167.3	1086.0	500.9	47.9
seda/zelena	1304.7	1213.9	559.9	53.5
hneda	357.0	332.1	153.2	14.6

Podmínky dobré aproximace splněny. Všechny teoretické četnosti jsou než 5.

Pearsonův χ^2 test

```
14 chisq.test(data, correct = F) # Pearsonuv chi-kvadratovy test
15 alpha <- ... # hladina vyznamnosti alpha
16 r <- ... # pocet variant znaku X (barva oci)
17 s <- ... # pocet variant znaku Y (barva vlasu)
18 q <- qchisq(1 - alpha, (r - 1) * (s - 1)) # dolni hranice kritickeho oboru
```

```

Pearson's Chi-squared test
data: data
X-squared = 1088.1, df = 6, p-value < 2.2e-16
```

```

q
1 12.59159
```

a) Test kritickým oborem

Hodnota testovací statistiky K je Kritický obor má tvar
 Protože, H_0 na hladině významnosti $\alpha =$

b) **Test p -hodnotou**

P -hodnota vyšla Protože p -hodnota, H_0 na hladině významnosti $\alpha =$

Pro zjištění míry závislosti v kontingenční tabulce použijeme koeficient.

```
26 lsr::cramersV(data) # Crameruv koeficient
```

```
  Crameruv.koeficient
1                0.2830494
```

27
28

Hodnota Cramérova koeficientu je

Interpretace výsledků: Znaky barva očí a barva vlasů jsou / nejsou stochasticky nezávislé. Mezi barvou očí a barvou vlasů existuje stupeň závislosti.

Příklad 11.2. Fisherův faktoriálový test

100 náhodně vybraných mužů a žen bylo dotázáno, zda dávají přednost nealkoholickému nápoji A či B. Údaje jsou uvedeny ve čtyřpolní kontingenční tabulce.

pref. nápoj	pohlaví	
	muž	žena
A	20	30
B	30	20

Na hladině významnosti $\alpha = 0.05$ testujte pomocí Fisherova faktoriálového testu hypotézu, že preferovaný typ nápoje nezáleží na pohlaví respondenta.

Řešení příkladu 11.2

- H_0 : Znaky pohlaví a preference stochasticky nezávislé.
- H_1 : Znaky pohlaví a preference stochasticky nezávislé.
- Hladina významnosti $\alpha =$

Fisherův faktoriálový test

```
29 data <- data.frame(muz = c(20, 30), zena = c(30, 20),
30                    row.names = c('A', 'B')) # vytvoření datové tabulky
31
32 # fisher.test()
33 # 1. argument ... datová tabulka
34 # alternative ... typ alternativní hypotézy
35 fisher.test(data, alternative = 'two.sided') # Fisheruv faktoriálový test
```

```
      Fisher's Exact Test for Count Data
data: data
p-value = 0.07134
alternative hypothesis: true odds ratio is not equal to 1
95 percent confidence interval:
 0.1846933 1.0640121
sample estimates:
odds ratio
0.4481632
```

36
37
38
39
40
41
42
43
44
45
46

Protože p -hodnota = je než $\alpha = 0.05$, nulovou hypotézu H_0 o nezávislosti preferovaného typu nápoje na pohlaví na hladině významnosti $\alpha =$

Příklad 11.3. Podíl šancí

Pro údaje z příkladu 11.2 vypočítejte podíl šancí a sestojte 95% asymptotický interval spolehlivosti pro logaritmus podílu šancí. Pomocí tohoto intervalu spolehlivosti testujte na asymptotické hladině významnosti $\alpha = 0.05$ hypotézu, že preferovaný typ nápoje nezáleží na pohlaví respondenta.

Řešení příkladu 11.3

- H_0 : \rightarrow
- H_1 : \rightarrow
- Hladina významnosti $\alpha =$

Podmínka dobré aproximace

Podmínky dobré aproximace splněny. Všechny teoretické četnosti jsou než 5.

```
47 a <- 20; b <- 30; c <- 30; d <- 20
48 data <- data.frame(muz = c(a, c), zena = c(b, d),
49                   row.names = c('A', 'B')) # vytvoreni datove tabulky
50 chisq.test(..., correct = ...) $expected # tabulka ocekavanych cetnosti
```

	muz	zena
A	25	25
B	25	25

51
52
53

Výpočet (logaritmu) podílu šancí

```
54 OR <- (a * d) / (b * c) # podil sancí
55 lnOR <- log(OR) # logaritmus podilu sancí
```

	OR	lnOR
1	0.4444444	-0.8109302

56
57

Podíl šancí $OR =$ Logaritmus podílu šancí $\ln(OR) =$

a) Test kritickým oborem

```
58 t0 <- log(OR) / sqrt(1 / a + 1 / b + 1 / c + 1 / d) # hodnota testovaci statistiky
59 q1 <- qnorm(alpha / 2) # horni hranice kritickeho oboru
60 q2 <- qnorm(1 - alpha / 2) # dolni hranice kritickeho oboru
```

	t0	q1	q2
1	-1.986365	-1.959964	1.959964

61
62

Hodnota testovací statistiky t_0 je Kritický obor má tvar
Protože, H_0 na hladině významnosti $\alpha =$

b) Test intervalem spolehlivosti

```
63 dh <- log(OR) + sqrt(1 / a + 1 / b + 1 / c + 1 / d) * qnorm(alpha / 2) # dolni
   hranice IS
64 hh <- log(OR) + sqrt(1 / a + 1 / b + 1 / c + 1 / d) * qnorm(1 - alpha / 2) # horni
   hranice IS
```

	dh	hh
1	-1.611082	-0.01077827

65
66

Interval spolehlivosti má tvar Protože, H_0
na hladině významnosti $\alpha =$

c) Test p -hodnotou

```
67 p.val <- 2 * min(pnorm(t0), 1 - pnorm(t0)) # p-hodnota
```

```
1 0.04699278
```

68
69

P -hodnota vyšla Protože p -hodnota, H_0 na hladině významnosti $\alpha =$

Interpretace výsledků: Znaky pohlaví a preference jsou / nejsou stochasticky nezávislé.

Poznámka: Uvedený výsledek je v rozporu s výsledkem, ke kterému dospěl Fisherův faktoriálový (přesný) test. Je to způsobeno tím, že test pomocí asymptotického intervalu spolehlivosti je pouze přibližný. Ke stejnému závěru, jaký jsme dostali u testování pomocí podílu šancí, dospějeme, pokud použijeme Pearsonův chí-kvadrát test o nezávislosti.

```
70 chisq.test(data, correct = F)
```

```
      Pearson's Chi-squared test  
data:  data  
X-squared = 4, df = 1, p-value = 0.0455
```

71
72
73
74
75

Ve funkci `chisq.test()` však můžeme zadat parametr `correct = T`, který provede korekci Pearsonova testu pro kontingenční tabulky typu 2×2 . Výsledek takto provedeného testu je již v souladu s Fisherovým faktoriálovým testem.

```
76 chisq.test(data, correct = T)
```

```
      Pearson's Chi-squared test with Yates' continuity correction  
data:  data  
X-squared = 3.24, df = 1, p-value = 0.07186
```

77
78
79
80
81