

11 Hodnocení kontingenčních tabulek

Příklad 11.1. Pearsonův χ^2 test

V roce 1950 zkoumali Yule a Kendall barvu očí a vlasů u 6800 mužů (viz tabulka 1; soubor `vlasy_oci.csv`).

Tabulka 1: Absolutní četnosti barvy vlasů a barvy očí mužů

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 $\alpha = 0.01$ zjistěte, zda mezi barvou očí a vlasů u mužů existuje závislost.

Řešení příkladu 11.1

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

```
1 data <- read.delim(..., header = T, row.names = 1) # nacteni datoveho souboru
2 n <- sum(...) # rozsah nahodneho vyberu
```

```
[1] 6800
```

3

Datový soubor obsahuje údaje o barvě očí a barvě vlasů mužů.

Podmínka dobré approximace

Pearsonův χ^2 test můžeme provést, je-li splněna podmínka dobré approximace (alespoň 80 % očekávaných četností je větších nebo rovných 5 a zbylých 20 % očekávaný četností neklesne pod hodnotu 2).

```
4 round(chisq.test(data, correct = F)$expected, 1) # tabulka ocekavanych ctnosti
```

	svetla	kastanova	cerna	rezava
modra	1169.5	1088.0	505.6	48.0
seda/zelena	1303.0	1212.3	563.3	53.4
hneda	356.5	331.7	154.1	14.6

5
6
7
8

Podmínka dobré approximace splněna. Všechny teoretické četnosti jsou než 5.

Pearsonův χ^2 test

```
9 chisq.test(data, correct = F) # Pearsonuv chi-kvadratovy test
10 alpha <- ... # hladina vyznamnosti alpha
11 r <- ... # pocet variant znaku X (barva oci)
12 s <- ... # pocet variant znaku Y (barva vlasu)
13 q <- qchisq(..., ...) # dolni hranice kritickeho oboru
```

14
15
16
17
18

```
Pearson's Chi-squared test
data: data
X-squared = 1073.5, df = 6, p-value < 2.2e-16
```

19
20

a) Test kritickým oborem

Hodnota testové statistiky $K = \dots$, kritický obor W má tvar Protože H_0 na hladině významnosti $\alpha = \dots$.

b) Test intervalem spolehlivosti

Pro Pearsonův χ^2 test vynescháváme testování intervalem spolehlivosti.

c) **Test p -hodnotou**

P -hodnota = Protože , H_0 na **asymptotické** hladině významnosti α =

Pro zjištění míry závislosti v kontingenční tabulce použijeme koeficient.

21 `lsr::cramersV(...)` # Crameruv koeficient

Crameruv.koeficient	
1	0.2809526

22
23

Interpretace výsledků: Mezi barvou očí a barvou vlasů mužů existuje / neexistuje statisticky významná stochastická závislost. Mezi barvou očí a barvou vlasů mužů existuje stupeň závislosti (V =).



Příklad 11.2. Test podílem šancí

Máme k dispozici údaje o frekvenci výskytu vysokého (11.9.7), středního (9.7.5) a nízkého (7.5.5) zakončení tří hlavních dlaňových linií na pravé a levé ruce 50 mužů a 50 žen z populace Mech a 105 mužů a 87 žen z populace Rajbanshi (viz tabulka 2; datový soubor 27-two-samples-probabilities-palmar.txt). Na hladině významnosti alpha = 0.05 testujte hypotézu o nezávislosti výskytu středního zakončení tří hlavních dlaňových linií na levé straně u žen a populace, ze které pocházejí.

Tabulka 2: Četnosti typů zakončení tří hlavních dlaňových linií na levé ruce u jedinců dvou indických populací

mech-L zakončení	pohlaví	
	muži	ženy
vysoké	4	5
střední	16	16
nízké	21	19
ostatní	9	10

raj-L zakončení	pohlaví	
	muži	ženy
vysoké	30	27
střední	24	17
nízké	38	21
ostatní	13	22

Řešení příkladu 11.2

24 `data <- data.frame(mech = c(16, 50 - 16), rajbanshi = c(17, 87 - 17), row.names = c(..., ...))`

mech rajbanshi
stredni 16 17
ostatni 34 70

25
26
27

Datový soubor obsahuje údaje o typu zakončení tří dlaňových linií žen, přičemž žen má střední zakončení a pochází z mechské populace, žen má jiné zakončení a pochází z mechské populace, žen má střední zakončení a pochází z populace Rajbanshi a žen má jiné zakončení a pochází z populace Rajbanshi.

Řešení příkladu 11.2

- H_0 : Typ zakončení a populace stochasticky nezávislé. → →
- H_1 : Typ zakončení a populace stochasticky nezávislé. → →
- Hladina významnosti α =

Podmínka dobré approximace

Nejprve musíme ověřit, zda je splněna podmínka dobré approximace (alespoň 80 % očekávaných četností je větších nebo rovných 5 a zbylých 20 % očekávaný četnosti neklesne pod hodnotu 2).

28 `round(chisq.test(...)$expected, ...)` # tabulka očekávaných četností

mech rajbanshi
stredni 12 21
ostatni 38 66

29
30
31

Podmínka dobré aproximace splněna. Všechny teoretické četnosti jsou než 5. Protože je podmínka dobré aproximace splněna, můžeme otestovat hypotézu ze zadání pomocí **testu podílem šancí**. Pokud by podmínka dobré aproximace splněna nebyla, museli bychom použít Fisherův faktoriálový (exaktní) test.

Výpočet (logaritmu) podílu šancí

```
32 a <- 16; b <- 17; c <- 34; d <- 70
33 OR <- ... / ... # podíl sancí ad / bc
34 lnOR <- log(...) # logaritmus podílu sancí
```

OR	lnOR
1 1.937716	0.6615101

35
36

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

Test podílem šancí

```
37 source('Sbirka-AS-I-2018-funkce-II.R')
38 odds.ratio.test(..., conf.level = ...)
39 alpha <- ... # hladina významnosti
40 qnorm(...) # hranice kritického oboru
41 qnorm(...) # hranice kritického oboru
```

OR	lnOR	t0	dh	hh	p
1 1.937716	0.6615101	1.628422	-0.1346817	1.457702	0.1034355

42
43

q1	q2
1 -1.959964	1.959964

44
45

a) Test kritickým oborem

Hodnota testové statistiky t_0 je Kritický obor má tvar
Protože , H_0 na **asymptotické** hladině významnosti $\alpha = \dots$

b) Test intervalem spolehlivosti

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

c) Test p-hodnotou

P -hodnota = Protože , H_0 na **asymptotické** hladině významnosti $\alpha = \dots$

Interpretace výsledků: Mezi typem zakončení tří hlavních dlaňových linií u žen a populací, ze které pochází, existuje / neexistuje statisticky významná stochastická závislost. U žen mechské / rajbanshské populace je 1.94 krát větší šance na výskyt středního zakončení tří hlavních dlaňových linií než u žen mechské / rajbanshské populace.



Příklad 11.3. Fisherův faktoriálový test

Máme k dispozici údaje o frekvenci výskytu vysokého (11.9.7), středního (9.7.5) a nízkého (7.5.5) zakončení tří hlavních dlaňových linií na pravé a levé ruce 50 mužů a 50 žen z populace Mech a 105 mužů a 87 žen z populace Rajbanshi (viz tabulka 2; datový soubor 27-two-samples-probabilities-palmar.txt). Na hladině významnosti $\alpha = 0.05$ testujte hypotézu o nezávislosti výskytu středního zakončení tří hlavních dlaňových linií na levé straně u žen a populace, ze které pocházejí. Zadanou hypotézu otestujte Fisherovým faktoriálovým testem.

Řešení příkladu 11.3

Fisherův faktoriálový test (jinak zvaný též Fisherův přesný (exaktní) test) používáme primárně, pokud podmínka dobré aproximace není splněna. Můžeme jej ale použít i v případě splnění podmínky dobré aproximace jako alternativní test k testu podílem šancí.

Fisherův faktoriálový test

- H_0 : Typ zakončení tří hlavních dlaňových linií a populace stochasticky nezávislé.
- H_1 : Typ zakončení tří hlavních dlaňových linií a populace stochasticky nezávislé.

- Hladina významnosti $\alpha = \dots$

```
46 fisher.test(data, alternative = ..., conf.level = ...) # Fisheruv faktorialovy test
```

```

Fisher's Exact Test for Count Data

data: data
p-value = 0.1455
alternative hypothesis: true odds ratio is not equal to 1
95 percent confidence interval:
0.8047687 4.6240301
sample estimates:
odds ratio
1.927942

```

47
48
49
50
51
52
53
54
55
56
57

a) **Test kritickým oborem**

Pro Fisherův faktoriálový test vynecháváme testování kritickým oborem.

b) **Test intervalem spolehlivosti**

Pro Fisherův faktoriálový test vynecháváme testování intervalem spolehlivosti.

c) **Test p -hodnotou**

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

Interpretace výsledků: Mezi typem zakončení tří hlavních dlaňových linií u žen a populací, ze které pocházejí, existuje / neexistuje statisticky významná stochastická závislost. ★