

# 11 Testování nezávislosti v kontingenčních tabulkách

## 11.1 Obecné kontingenční tabulky

Předpokládáme, že máme  $n$  objektů, na nichž zjišťujeme hodnoty  $(x_1, y_1)^T, \dots, (x_n, y_n)^T$  dvou nominálních veličin  $X$  a  $Y$ , veličina  $X$  má  $r$  variant, veličina  $Y$  má  $s$  variant. Tyto dvojice považujeme za realizace náhodného výběru rozsahu  $n$  z dvourozměrného rozložení, kterým se řídí dvourozměrný diskrétní náhodný vektor  $(X, Y)^T$ . Zjištěné absolutní simultánní četnosti  $n_{jk}$  dvojice variant  $(x_{[j]}, y_{[k]})^T$  uspořádáme do kontingenční tabulky (viz tabulka 11.1):

Tabulka 11.1: Kontingenční tabulka absolutních četností

X	Y			$n_{j.}$
	$y_{[1]}$	$\dots$	$y_{[s]}$	
$x_{[1]}$	$n_{11}$	$\dots$	$n_{1s}$	$n_{1.}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_{[r]}$	$n_{r1}$	$\dots$	$n_{rs}$	$n_{r.}$
$n_{.k}$	$n_{.1}$	$\dots$	$n_{.s}$	$n$

Tabulku doplníme o marginální četnosti:  $n_{j.} = n_{j1} + \dots + n_{js}$  je marginální absolutní četnost varianty  $x_{[j]}$ ,  $j = 1, \dots, r$ ,  $n_{.k} = n_{1k} + \dots + n_{rk}$  je marginální absolutní četnost varianty  $y_{[k]}$ ,  $k = 1, \dots, s$ .

Na hladině významnosti  $\alpha$  testujeme  $H_0: X, Y$  jsou stochasticky nezávislé náhodné veličiny proti  $H_1: X, Y$  nejsou stochasticky nezávislé náhodné veličiny.

Testová statistika  $K = \sum_{j=1}^r \sum_{k=1}^s \frac{(n_{jk} - \frac{n_{j.}n_{.k}}{n})^2}{\frac{n_{j.}n_{.k}}{n}}$ , kde  $\frac{n_{j.}n_{.k}}{n}$  je tzv. teoretická četnost dvojice variant  $(x_{[j]}, y_{[k]})^T$ .

Platí-li  $H_0$ , pak  $K$  se asymptoticky řídí rozložením  $\chi^2((r-1)(s-1))$ . Kritický obor:  $W = \langle \chi^2_{1-\alpha}((r-1)(s-1)); \infty \rangle$ . Hypotézu o nezávislosti veličin  $X, Y$  tedy zamítáme na asymptotické hladině významnosti  $\alpha$ , když  $K \in W$ . Tento test se nazývá Pearsonův  $\chi^2$  test nezávislosti.

Podmínka dobré aproximace: Rozložení statistiky  $K$  lze aproximovat rozložením  $\chi^2((r-1)(s-1))$ , pokud teoretické četnosti aspoň v 80 % případů nabývají hodnoty větší nebo rovné 5 a ve zbylých 20 % neklesnou pod 2. Není-li splněna podmínka dobré aproximace, doporučuje se slučování některých variant. Sílu závislosti mezi veličinami  $X, Y$  měří Cramérův koeficient:  $V = \sqrt{\frac{K}{n(m-1)}}$ , kde  $m = \min\{r, s\}$ . Cramérův koeficient  $V$  nabývá hodnot mezi 0 a 1. Čím blíže je k 1, tím je závislost mezi  $X$  a  $Y$  těsnější, čím blíže je k 0, tím je tato závislost volnější. Stupnice míry závislosti je uvedena v tabulce 11.2.


Tabulka 11.2: Stupnice míry závislosti pro Cramérův koeficient

Cramérův koeficient $V$	Interpretace
$\langle 0, 0; 0, 1 \rangle$	zanedbatelný stupeň závislosti
$\langle 0, 1; 0, 3 \rangle$	slabý stupeň závislosti
$\langle 0, 3; 0, 7 \rangle$	střední stupeň závislosti
$\langle 0, 7; 1, 0 \rangle$	silný stupeň závislosti

### Příklad 11.1. Řešený příklad

Načtete datový soubor 22-multinom-palmar-lines.txt obsahující údaje o zakončení tří dlaňových linií (vysoké, střední, nízké) a o barvě vlasů (světlá, střední, tmavá) u 100 mužů a 100 žen. Na asymptotické hladině významnosti  $\alpha = 0,01$  testujte hypotézu o nezávislosti typu zakončení tří dlaňových linií a barvě vlasů u mužů. Testování proveďte (1) kritickým oborem; (2)  $p$ -hodnotou. Míru závislosti kvantifikujte Cramérovým koeficientem.

## Řešení příkladu 11.1

Nejprve je třeba ověřit podmínku dobré aproximace. Aby byla podmínka splněna, je třeba, aby v alespoň 80 % případů nabývaly teoretické četnosti  $\frac{n_{j \cdot} n_{\cdot k}}{n}$  hodnoty větší nebo rovné 5 a ve zbylých 20 % případů nebyly menší než 2. V softwaru  získáme teoretické četnosti jako výstup expected funkce `chisq.test()`.

```
1 data <- read.delim('22-multinom-palmar-lines.txt', sep = '\t', dec = '.')
2 data.M <- data.frame(data[, 2:4], row.names = data[, 1])
3 chisq.test(data.M)$expected
```

	Hi	Mi	Lo
LiH	7,04	5,28	3,68
MH	18,48	13,86	9,66
DaH	18,48	13,86	9,66

4  
5  
6  
7

Z výstupu vidíme, že pouze jedna teoretická četnost z devíti (tj. 11.11 %) je menší než 5, přičemž tato četnost nabývá hodnoty 3,68, což ve více než 2. Podmínka dobré aproximace je tedy splněna.

Na asymptotické hladině významnosti  $\alpha = 0,01$  testujeme  $H_0: X$  a  $Y$  jsou stochasticky nezávislé náhodné veličiny. proti  $H_1: X$  a  $Y$  nejsou stochasticky nezávislé náhodné veličiny. K testování použijeme Pearsonův  $\chi^2$  test nezávislosti implementovaný ve funkci `chisq.test()`. Výstupem funkce je realizace testové statistiky  $K$  a  $p$ -hodnota. Dolní hranici kritického oboru  $\chi^2_{1-\alpha}((r-1)(s-1))$ , kde  $r = 3$  a  $s = 3$ , dopočítáme příkazem `qchisq()`. Nakonec kvantifikujeme míru závislosti pomocí Cramérova koeficientu. Jeho hodnotu vypočítáme pomocí funkce `cramersV()` z knihovny `lsr`.

```
8 alpha <- 0.01
9 r <- 3; s <- 3
10 qchisq(1 - alpha, (r - 1) * (s - 1)) # 13,2767
11 chisq.test(data.M)
12 lsr::cramersV(data.M) # 0,1014841
```

Pearson's Chi-squared test

data: data.M  
X-squared = 2,0598, df = 4, p-value = 0,7248

13  
14  
15  
16  
17

Realizace testové statistiky  $k = 2,0598$ , kritický obor  $W = (13,2767; \infty)$ . Protože  $k \notin W$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti  $\alpha = 0,01$ . Protože  $p$ -hodnota = 0,7248 je větší než  $\alpha = 0,01$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti  $\alpha = 0,01$ . Mezi typem zakončení tří dlaňových linií a barvou vlasů u mužů neexistuje statisticky významná stochastická závislost. Mezi typem zakončení tří dlaňových linií a barvou vlasů u mužů existuje slabý stupeň závislosti ( $V = 0,1015$ ). ★

## Příklad 11.2. Neřešený příklad

Načtěte datový soubor `20-more-samples-probabilities-pubis.txt` obsahující údaje o frekvenci výskytu tří stupňů změn ((i) žádné změny, (ii) stopové až malé změny, (iii) střední až výrazné změny) kostního reliéfu na vnitřní straně stydké kosti (*os pubis*) v blízkosti spony stydké (*symphysis pubica*) u žen z kosterních souborů tří populací: evropského původu, afrického původu a Inuitů. Na asymptotické hladině významnosti  $\alpha = 0,10$  testujte hypotézu o nezávislosti míry změn kostního reliéfu na vnitřní straně stydké kosti a populace. Testování proveďte (1) kritickým oborem; (2)  $p$ -hodnotou. Míru závislosti kvantifikujte Cramérovým koeficientem.

**Výsledky:** podmínka dobré aproximace je splněna (devět z devíti (100 %) teoretických četností je větších než 5);  $k = 9,4351$ ,  $r = 3$ ,  $s = 3$ ,  $W = (7,7794; \infty)$ ;  $p$ -hodnota = 0,0511,  $\alpha = 0,10$ ;  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,10$ ; Cramérův koeficient:  $V = 0,1517$ . ★

## 11.2 Čtyřpolní kontingenční tabulky

Je-li  $r = s = 2$ , jedná se o čtyřpolní kontingenční tabulku, v níž používáme označení:  $n_{11} = a$ ,  $n_{12} = b$ ,  $n_{21} = c$ ,  $n_{22} = d$ .

Hypotézu o nezávislosti veličin  $X$ ,  $Y$  můžeme ve čtyřpolní kontingenční tabulce testovat několika způsoby.

- Pomocí Pearsonova  $\chi^2$  testu nezávislosti (v tomto případě má kritický obor tvar  $W = (\chi_{1-\alpha}^2(1); \infty)$ ).
- Pomocí Fisherova přesného testu ( $p$ -hodnotu tohoto testu, kterou nám poskytne statistický software, porovnáme s hladinou významnosti  $\alpha$ . Je-li  $p$ -hodnota  $\leq \alpha$ , pak hypotézu o nezávislosti zamítáme na hladině významnosti  $\alpha$ ).
- Pomocí výběrového podílu šancí  $OR = \frac{ad}{bc}$ . Za platnosti  $H_0$  je  $OR$  blízky 1 testová statistika  $T_0 = \frac{\ln OR}{\sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}}}$

se asymptoticky řídí rozložením  $N(0, 1)$ . Kritický obor:  $W = (-\infty; -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}; \infty)$ .

$H_0$  zamítáme na asymptotické hladině významnosti  $\alpha$ , když  $T_0 \in W$ . Test o nezávislosti lze provést i pomocí 100(1 -  $\alpha$ )% asymptotického intervalu spolehlivosti pro logaritmus teoretického podílu šancí  $o\rho$ , který je dán vzorcem:  $(d; h) = \left( \ln OR - \sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}} u_{1-\alpha/2}; \ln OR + \sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}} u_{1-\alpha/2} \right)$ .

Jestliže interval spolehlivosti neobsahuje 0, pak hypotézu o nezávislosti zamítneme na asymptotické hladině významnosti  $\alpha$ .

**Upozornění:** Pokud bychom chtěli získat interval spolehlivosti nikoliv pro  $\ln o\rho$ , ale pro  $o\rho$ , stačí uvedené meze odlogaritmovat. Při testování hypotézy o nezávislosti veličin  $X$ ,  $Y$  pomocí tohoto intervalu spolehlivosti pak zjišťujeme, zda interval pokrývá číslo 1. Pokud ne, pak hypotézu o nezávislosti zamítneme na asymptotické hladině významnosti  $\alpha$ .

### Příklad 11.3. Řešený příklad

Načtěte datový soubor 25-one-sample-probability-dermatoglyphs.txt obsahující údaje o frekvenci výskytu dermatoglyfických vzorů *vír*, *smýčka* a *oblouček* na deseti prstech 470 jedinců (235 mužů a 235 žen) bagathské populace z Araku Valley. Na hladině významnosti  $\alpha = 0,05$  testujte hypotézu o nezávislosti mezi výskytem dermatoglyfického vzoru *smýčka* a pohlavím u bagathské populace z Araku Valley. Testování proveďte (a) pomocí Pearsonova  $\chi^2$  testu nezávislosti ((1) kritickým oborem, (2)  $p$ -hodnotou); (b) pomocí Fisherova přesného testu ((1)  $p$ -hodnotou); (c) pomocí podílu šancí ((1) kritickým oborem, (2) intervalem spolehlivosti, (3)  $p$ -hodnotou). Pro situaci (a) vypočítejte a interpretujte Cramérův koeficient; pro situaci (c) vypočítejte a interpretujte hodnotu výběrového podílu šancí.

### Řešení příkladu 11.3

Na hladině významnosti  $\alpha = 0,05$  testujeme  $H_0$ :  $X$  a  $Y$  jsou stochasticky nezávislé náhodné veličiny. proti  $H_1$ :  $X$  a  $Y$  nejsou stochasticky nezávislé náhodné veličiny.

(a) Nejprve je třeba ověřit podmínku dobré aproximace.

```
18 data <- read.delim('25-one-sample-probability-dermatoglyphs.txt', sep = '\t', dec = '.')
19 data.L <- data.frame(muži = c(1246, 235 * 10 - 1246),
20                       ženy = c(1349, 235 * 10 - 1349),
21                       row.names = c('smýčka', 'jine'))
22 chisq.test(data.L)$expected
```

```
      muži  ženy
smýčka 1297,5 1297,5
jine   1052,5 1052,5
```

23  
24  
25

Z výstupu vidíme, že všechny teoretické četnosti (tj. 100%) jsou větší než 5, podmínka dobré aproximace je tedy splněna.

K testování použijeme Pearsonův  $\chi^2$  test nezávislosti implementovaný ve funkci `chisq.test()`. Výstupem funkce je realizace testové statistiky  $K$  a  $p$ -hodnota. Dolní hranici kritického oboru  $\chi^2_{1-\alpha}(1)$  dopočítáme příkazem `qchisq()`. Nakonec kvantifikujeme míru závislosti pomocí Cramérova koeficientu (funkce `cramersV()` z knihovny `lsr`).


```
26 alpha <- 0.05
27 qchisq(1 - alpha, 1) # 3,841459
28 chisq.test(data.L)
29 lsr::cramersV(data.L) # 0,04364208
```

```

      Pearson's Chi-squared test with Yates' continuity correction
data: data.L
X-squared = 8,9518, df = 1, p-value = 0,002772
```

30  
31  
32  
33  
34

Realizace testové statistiky  $k = 8,9518$ , kritický obor  $W = \langle 3,8415; \infty \rangle$ . Protože  $K \in W$ ,  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,05$ . Protože  $p$ -hodnota =  $0,002772$  je menší než  $\alpha = 0,05$ ,  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,05$ . Mezi výskytem dermatoglyfického vzoru *smýčka* a pohlavím u bagathské populace z Araku Valley existuje statisticky významná stochastická závislost. Mezi výskytem dermatoglyfického vzoru *smýčka* a pohlavím u bagathské populace z Araku Valley existuje zanedbatelný stupeň závislosti ( $V = 0,04364$ ).

(b) Fisherův přesný test provedeme pomocí funkce `fisher.test()` implementované v softwaru . Výstupem funkce je interval spolehlivosti a  $p$ -hodnota.



```
35 fisher.test(data.L, alternative = 'two.sided', conf.level = 0.95)
```

```

      Fisher's Exact Test for Count Data
data: data.L
p-value = 0,002768
alternative hypothesis: true odds ratio is not equal to 1
95 percent confidence interval:
 0,7451425 0,9412385
sample estimates:
 odds ratio
 0,8375093
```

36  
37  
38  
39  
40  
41  
42  
43  
44  
45  
46

Protože  $p$ -hodnota =  $0,002768$  je menší než  $\alpha = 0,05$ ,  $H_0$  zamítáme na hladině významnosti  $\alpha = 0,05$ . Mezi výskytem dermatoglyfického vzoru *smýčka* a pohlavím u bagathské populace z Araku Valley existuje statisticky významná stochastická závislost.

(c) Test podílem šancí provedeme pomocí funkce `odds.ratio.test()` implementované v -skriptu `AS-sbirka-funkce.R`, který je součástí této publikace. -skript načteme příkazem `source()`. Výstupem funkce `odds.ratio.test()` je hodnota podílu šancí OR, logaritmus podílu šancí  $\ln OR$ , realizace testové statistiky  $t_0$ , interval spolehlivosti pro logaritmus podílu šancí a  $p$ -hodnota. Hranice kritického oboru dopočítáme příkazem `qnorm()`.

```
47 source('AS-sbirka-funkce.R')
48 alpha <- 0.05
49 qnorm(alpha / 2) # -1,959964
50 qnorm(1 - alpha / 2) # 1,959964
51 odds.ratio.test(data.L, conf.level = 0.95)
```

```

      OR      lnOR      t0      dh      hh      p
1 0,8375 -0,1774 -3,0203 -0,2925 -0,0623 0,0025
```

52  
53

Realizace testové statistiky  $t_0 = -3,0203$ , kritický obor  $W = (-\infty; -1,96) \cup \langle 1,96; \infty \rangle$ . Protože  $t_0 \in W$ ,  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,05$ . Interval spolehlivosti  $IS = (-0,2925; -0,0623)$ . Protože

$c = 0 \notin IS$ ,  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,05$ . Protože  $p$ -hodnota = 0,0025 je menší než  $\alpha = 0,05$ ,  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,05$ . Mezi výskytem dermatoglyfického vzoru *smyčka* a pohlavím u bagathské populace z Araku Valley existuje statisticky významná stochastická závislost. Podíl šancí výskytu dermatoglyfického vzoru *smyčka* mužů ku ženám vyšel 0,8375. V takovém případě bývá nicméně lepší interpretovat převrácenou hodnotu podílu šancí, čili  $1/0,8375 = 1,1940$ . Šance na výskyt dermatoglyfického vzoru *smyčka* u žen bagathské populace z Araku Valley je 1,1940-krát větší než u mužů bagathské populace z Araku Valley. ★

#### Příklad 11.4. Neřešený příklad

Načtete datový soubor `26-two-samples-probabilities-palmar.txt` obsahující údaje o frekvenci výskytu vysokého (11.9.7), středního (9.7.5), nízkého (7.5.5) a jiného zakončení dlaňových linií na pravé a levé straně 50 mužů a 50 žen z populace Mech a 105 mužů a 87 žen z populace Rajbanshi. Na hladině významnosti  $\alpha = 0,01$  testujte hypotézu o nezávislosti výskytu nízkého zakončení dlaňových linií na pravé straně u mužů z populace Mech a u mužů z populace Rajbanshi. Testování proveďte (a) pomocí Pearsonova  $\chi^2$  testu nezávislosti ((1) kritickým oborem, (2)  $p$ -hodnotou); (b) pomocí Fisherova přesného testu ((1)  $p$ -hodnotou); (c) pomocí podílu šancí ((1) kritickým oborem, (2) intervalem spolehlivosti, (3)  $p$ -hodnotou). Pro situaci (a) vypočítejte a interpretujte Cramérův koeficient; pro situaci (c) vypočítejte a interpretujte hodnotu výběrového podílu šancí.

**Výsledky:** (a) Pearsonův  $\chi^2$  test nezávislosti: podmínka dobré aproximace je splněna (čtyři ze čtyř (100 %) teoretických četností jsou větší než 5);  $k = 9,4673$ ,  $W = (6,6349; \infty)$ ;  $p$ -hodnota = 0,002092,  $\alpha = 0,01$ ;  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,01$ ; Cramérův koeficient  $V = 0,2471$ ; (b) Fisherův přesný test:  $p$ -hodnota = 0,001676,  $\alpha = 0,01$ ;  $H_0$  zamítáme na hladině významnosti  $\alpha = 0,01$ ; (c) test podílem šancí:  $t_0 = 3,1954$ ,  $W = (-\infty; -2,5758) \cup (2,5758; \infty)$ ;  $IS = (0,2255; 2,1008)$ ,  $c = 0$ ;  $p$ -hodnota = 0,0014,  $\alpha = 0,01$ ;  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha = 0,01$ ; výběrový podíl šancí  $OR = 3,2000$ . ★