

Téma 11: Hodnocení kontingenčních tabulek

Úkol 1.: Testování hypotézy o nezávislosti, měření síly závislosti

V roce 1950 zkoumali Yule a Kendall barvu očí a vlasů u 6800 mužů.

Barva očí	Barva vlasů			
	světlá	kaštanová	černá	rezavá
modrá	1768	807	180	47
šedá nebo zelená	946	1387	746	53
hnědá	115	438	288	16

Na asymptotické hladině významnosti 0,05 testujte hypotézu o nezávislosti barvy očí a barvy vlasů. Vypočítejte Cramérův koeficient. Simultánní četnosti znázorněte graficky.

Návod:

Testujeme hypotézu H_0 : X, Y jsou stochasticky nezávislé náhodné veličiny proti

H_1 : X, Y nejsou stochasticky nezávislé náhodné veličiny. Testová statistika má tvar:

$$K = \sum_{j=1}^r \sum_{k=1}^s \left(\frac{n_{jk} - \frac{n_{j.}n_{.k}}{n}}{\frac{n_{j.}n_{.k}}{n}} \right)^2. \text{ Platí-li } H_0, \text{ pak } K \text{ se asymptoticky řídí rozložením } \chi^2((r-1)(s-1)),$$

kde r, s jsou počty variant jednotlivých proměnných.

Hypotézu o nezávislosti veličin X, Y tedy zamítáme na asymptotické hladině významnosti α , když $K \geq \chi^2_{1-\alpha}((r-1)(s-1))$.

V našem případě zjistíme, že $K = 1088,15$, $r = 3$, $s = 4$, $\chi^2_{1-\alpha}((r-1)(s-1)) = \chi^2_{0,95}(6) = 12,592$ a protože hodnota testové statistiky $K = 1088,15 \geq 12,592$, zamítáme nulovou hypotézu na asymptotické hladině významnosti 0,05.

Cramérův koeficient: $V = \sqrt{\frac{K}{(r-1)n}}$, kde $m = \min\{r,s\}$. Tento koeficient nabývá hodnot

mezi 0 a 1. Čím blíže je 1, tím je těsnější závislost mezi X a Y, čím blíže je 0, tím je tato závislost volnější.

Význam hodnot Cramérova koeficientu:

mezi 0 až 0,1 ... zanedbatelná závislost,

mezi 0,1 až 0,3 ... slabá závislost,

mezi 0,3 až 0,7 ... střední závislost,

mezi 0,7 až 1 ... silná závislost.

Otevřeme datový soubor oci_vlasy.sta o 12 případech a třech proměnných (OCI, VLASY, CETNOST).

Před provedením testu je zapotřebí ověřit podmínky dobré aproximace:

Statistiky – Základní statistiky/tabulky – Kontingenční tabulky - Specif. tabulky – List 1 OCI, List 2 VLASY, OK, Váhy - CETNOST, Stav zapnuto, OK – na záložce Možnosti zaškrtneme Očekávané četnosti – Výpočet.

Souhrnná tab.: Očekávané četnosti (oci_vlas
 Četnost označených buněk > 10
 Pearsonův chí-kv. : 1088,15, sv=6, p=0,0000

OCI	VLAS světla	VLAS kaštan	VLAS černá	VLAS rezav	Radk souči
modrá	1167,	1085,	500,8	47,86	2802,
sedá nebo hnědá	1304,	1213,	559,8	53,49	3132,
	357,0	332,	153,2	14,63	857,0
Vs.skup.	2829,	2632,	1214,	116,0	6791,

Podmínky dobré aproximace jsou splněny. Všechny teoretické četnosti jsou větší než 5. Nyní budeme testovat hypotézu o nezávislosti proměnných OCI, VLASY.

Návrat do Výsledky; kontingenční tabulky – na záložce Detaily zaškrtneme Pearsonův & M-L Chi - kvadrát, Phi & Cramerovo V – Detailní výsledky – Detailní 2 rozm. tabulky.


Statist.	Chi-kv.	sv	p
Pearsonův chí-k	1088,	df=	p=0,0
M-V chí-kvadr.	1155,	df=	p=0,0
FI	,4002		
Kontingenční ko	,3716		
Cramér. V	,2830		

Ve výstupní tabulce najdeme mj. hodnotu testové statistiky (Pearsonův chí-kv = 1088,149) s počtem stupňů volnosti (sv = 6) a odpovídající p-hodnotou (p = 0,0000), dále Cramérův koeficient (V = 0,283). Protože p-hodnota je mnohem menší než 0,05, nulovou hypotézu o nezávislosti barvy očí a barvy vlasů zamítáme na asymptotické hladině významnosti 0,05. Cramérův koeficient svědčí o slabé závislosti barvy očí a vlasů.

Pro grafické znázornění četností se vrátíme do Výsledky; kontingenční tabulky – Detailní výsledky – 3D histogramy. Po vytvoření grafu 2 krát poklepeme levým tlačítkem myši na pozadí grafu:

Rozvržení grafu – Typ Šipky – OK. Graf lze natáčet pomocí volby Zorný bod.

Dvourozměrné rozdělení: OCI x VLASY



Úkol k samostatnému řešení: Na hladině významnosti 0,05 testujte hypotézu o nezávislosti pedagogické hodnosti a pohlaví a vypočtěte Cramérův koeficient vyjadřující intenzitu závislosti pedagogické hodnosti na pohlaví, jsou-li k dispozici následující údaje:

pohlaví	pedagogická hodnost		
	odb. asistent	docent	profesor
muž	32	15	8
žena	34	8	3

Výsledek: Podmínky dobré aproximace jsou splněny, pouze jediná teoretická četnost klesne po 5. Testová statistika K nabývá hodnoty 3,5, $p = 0,1739$, tedy na asymptotické hladině významnosti 0,05 nezamítáme hypotézu o nezávislosti pedagogické hodnosti a pohlaví. Cramérův koeficient: $V = 0,187$.

Úkol 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.

preferovaný nápoj	pohlaví	
	muž	žena
A	20	30
B	30	20

Na hladině významnosti 0,05 testujte pomocí Fisherova faktoriálového testu hypotézu, že preferovaný typ nápoje nezáleží na pohlaví respondenta.

Návod: Vytvoříme nový datový soubor o třech proměnných NAPOJ, POHLAVI, CETNOST a čtyřech případech. Do proměnné NAPOJ napíšeme dvakrát pod sebe 1 (nápoj A) a dvakrát

pod sebe 2 (nápoj B). Do proměnné POHLAVI napíšeme jedničku (1 – muž) a dvojku (2 – žena) a znovu jedničku a dvojku. D proměnné CETNOST napíšeme uvedené četnosti. Statistika – Základní statistika/tabulky – Kontingenční tabulky - Specif. tabulky – List 1 NAPOJ, List 2 POHLAVI, OK, Váhy - CETNOST, Stav zapnuto, OK – na záložce Možnosti zaškrtneme Fisher exakt, Yates, McNemar (2x2) – Detailní výsledky – Detailní 2-rozm. tabulky.

Statist.	Statist. : POHLAVI(2) x NAJ		
	Chi-kvadr	sv	p
Pearsonuv chi-kv	4,000	df=	p=,04
M-V chi-kvadr.	4,027	df=	p=,04
Yatesuv chi-kv.	3,240	df=	p=,07
Fisheruv přesný, 2-stranný			p=,03
McNemaruv chi-kv (B/C)	,0250	df=	p=,87
	,0166	df=	p=,89

Ve výstupní tabulce je mimo jiné uvedena p-hodnota pro oboustranný a jednostranný test. V našem případě se jedná o oboustranný test (nevíme, zda muži více preferují nápoj A či nápoj B než ženy), zajímáme se tedy o Fisherův přesný, 2-str. Ta je 0,07134. Protože p-hodnota je větší než 0,05, nezamítáme na hladině významnosti 0,05 hypotézu, že preferovaný typ nápoje nezáleží na pohlaví respondenta.

Úkol 3.: Podíl šancí

Pro údaje z úkolu 2 vypočítejte podíl šancí a sestrojte 95% asymptotický interval spolehlivosti pro podíl šancí. Pomocí tohoto intervalu spolehlivosti testujte na asymptotické hladině významnosti 0,05 hypotézu, že preferovaný typ nápoje nezáleží na pohlaví respondenta.

Návod: Nejprve zopakujme teorii:

Ve čtyřpolních tabulkách používáme charakteristiku $OF = \frac{a}{c}$ která se nazývá podíl šancí (odds ratio). Můžeme si představit, že pokus se provádí za dvojích různých okolností a může skončit buď úspěchem nebo neúspěchem.

Výsledek pokusu	okolnosti		n _j
	I	II	
úspěch	a	b	a+b
neúspěch	c	d	c+d
n _k	a+c	b+d	n

Poměr počtu úspěchů k počtu neúspěchů (tzv. šance) za 1. okolností je $\frac{a}{c}$, za druhých

okolností je $\frac{b}{d}$. Podíl šancí je $OF = \frac{a}{c}$. Považujeme ho za odhad skutečného podílu šancí

op. Pomocí 100(1- α)% asymptotického intervalu spolehlivosti pro logaritmus skutečného podílu šancí $\ln op$ lze na asymptotické hladině významnosti α testovat hypotézu o nezávislosti nominálních veličin X a Y. Asymptotický 100(1- α)% interval spolehlivosti pro přirozený logaritmus skutečného podílu šancí má meze:

$\ln OR_{\pm} \pm \sqrt{\frac{1}{i} + \frac{1}{j} + \frac{1}{k} + \frac{1}{l}}$. Jestliže interval spolehlivosti nezahrne 0, pak hypotézu o nezávislosti zamítneme na asymptotické hladině významnosti α .

V našem případě podíl šancí vypočteme ručně. $OR = \frac{ad}{bc} = \frac{20 \cdot 1}{5 \cdot 4} = 4$. Dolní a horní

mez intervalu spolehlivosti pro OR zjistíme pomocí STATISTÍKY. Vytvoříme datový soubor o dvou proměnných DM a HM a dvou případech. Do Dlouhého jména proměnné DM napíšeme vzorec pro dolní mez:

$$= \log(4/9) - \sqrt{1/20 + 1/30 + 1/30 + 1/20} * VNormal(0,975;0;1)$$

a analogicky do Dlouhého jména proměnné HM napíšeme vzorec pro horní mez:

$$= \log(4/9) + \sqrt{1/20 + 1/30 + 1/30 + 1/20} * VNormal(0,975;0;1)$$

	1 DM	2 HM
1	-1,61	-0,01

Výsledek: $-1,61108 < \ln OR < -0,01078$ s pravděpodobností přibližně 0,95. Protože tento interval spolehlivosti neobsahuje 0, na asymptotické hladině významnosti 0,05 zamítáme hypotézu, že preferovaný typ nápoje nezáleží na pohlaví respondenta.

Tento výsledek je v rozporu s výsledkem, ke kterému dospěl Fisherův přesný test. Je to způsobeno tím, že test pomocí asymptotického intervalu spolehlivosti je pouze přibližný.

Úkol k samostatnému řešení: 18 mužů onemocnělo určitou chorobou. Někteří z nich se léčili, jiní ne. Někteří se uzdravili, jiní zemřeli. Údaje jsou uvedeny ve čtyřpolní kontingenční tabulce.

	přežití	
	ano	ne
léčení	5	3
ne	6	4

Vypočtete a interpretujte podíl šancí. Pomocí intervalu spolehlivosti pro podíl šancí testujte na asymptotické hladině významnosti 0,05 hypotézu, že přežití nezávisí na léčení proti tvrzení, že léčení zvyšuje šance na přežití.

Výsledek: $OR_{\underline{}} = -1,49$, nulovou hypotézu nezamítáme asymptotické hladině významnosti 0,05, protože levostranný 95% asymptotický interval spolehlivosti pro logaritmus podílu šancí je $(-1,49; \infty)$.

Úkol 4.: Testování hypotézy o symetrii ve čtyřpolní tabulce (McNemarův test)

Máme náhodný výběr 18 pacientů, kteří byli léčeni dvěma různými antihypertenzivy A a B. Každý pacient dostával po dobu jednoho měsíce lék A a po odeznění jeho případných účinků dostával po dobu jednoho měsíce lék B. Výsledek byl klasifikován jako úspěch nebo neúspěch. Za úspěch byl pokládán pokles krevního tlaku alespoň o 15 mm Hg. Každý jiný výsledek byl považován za neúspěch. Léčba A byla úspěšná u 4 pacientů, přičemž u jednoho z nich byla úspěšná i léčba B. Léčba B byla úspěšná u 10 pacientů. Na asymptotické hladině významnosti 0,05 testuje hypotézu, že pravděpodobnost úspěchu je stejná pro oba léky.

Výsledek: Testová statistika McNemarova testu se realizuje hodnotou 3, kritický obor je $W_{\infty} = 3,84$, tedy nulovou hypotézu nezamítáme na asymptotické hladině významnosti 0,05.