

# Statistika

(MD360P03Z, MD360P03U)  
ak. rok 2007/2008

Karel Zvára

karel.zvara@mff.cuni.cz  
<http://www.karlin.mff.cuni.cz/~zvara>

(naposledy upraveno 17. prosince 2007)



Statistika (MD360P03Z, MD360P03U) ak. rok 2007/2008

## test nezávislosti kvalitativních znaků

- vyšetřujeme **současně** dva znaky v nominálním měřítku u  $n$  nezávislých statistických jednotek
- $n_{ij}$  je počet jednotek, kde je současně  $i$ -tá hodnota prvního znaku a  $j$ -tá hodnota druhého znaku
- celkem je  $i$ -tá hodnota prvního znaku u  $n_{i\bullet} = \sum_j n_{ij}$  jednotek,  $j$ -tá hodnota druhého znaku u  $n_{\bullet j} = \sum_i n_{ij}$  jednotek
- kdyby byly znaky nezávislé, byl by pro každou hodnotu jednoho znaku poměr mezi četnostmi hodnot druhého znaku podobný, proto očekávané četnosti jsou  $o_{ij} = \frac{n_{i\bullet} n_{\bullet j}}{n}$  (podmíněné psti stejné)
- výpočet  $\chi^2$  a jeho hodnocení stejně jako u homogenity

## příklad: předvolební průzkum

zprávy TV XY	strana		celkem
	A	B	
sledoval	11	4	15
nesledoval	6	9	15
celkem	17	13	30

zprávy TV XY	strana		celkem
	A	B	
sledoval	73 %	27 %	100 %
nesledoval	40 %	60 %	100 %
celkem	57 %	43 %	100 %

zprávy TV XY	strana		celkem
	A	B	
sledoval	65 %	31 %	50 %
nesledoval	35 %	69 %	50 %
celkem	100 %	100 %	100 %

- 30 voličů bylo dotázáno, které ze dvou stran dají přednost
- souvisí odpovědi se sledováním večerních zpráv na dané TV stanici?
- znamená něco nestejně zastoupení příznivců stran u těch, kteří sledovali?
- znamenají něco nestejně podíly těch, kteří sledovali mezi příznivci dvou stran?

## příklad: souvisí plánované těhotenství se vzděláním?

vzdělání	plánované		celkem
	ne	ano	
základní	20	14	34
střední	16	31	47
VŠ	5	13	18
celkem	41	58	99

  

vzdělání	plánované		celkem
	ne	ano	
základní	58,8 %	42,1 %	100 %
střední	34,0 %	66,0 %	100 %
VŠ	27,8 %	72,2 %	100 %
celkem	41,4 %	58,6 %	100 %

- je souvislost mezi odpověďmi o plánovaném těhotenství a vzděláním matek?
- kdyby byly znaky nezávislé, byly by podmíněny pravděpodobnosti pro jednotlivá vzdělání stejné, tedy jejich odhady by byly podobné
- test vlastně porovnává procenta u jednotlivých vzdělání
- chi-kvadrát test porovnává skutečně zjištěné četnosti s tím, jaké četnosti bychom v průměru očekávali, kdyby platila nulová hypotéza

## příklad: plánovaná těhotenství

skutečné četnosti (očekávané četnosti)

vzdělání	plánované		celkem
	ne	ano	
základní	20 (14,08)	14 (19,92)	34
střední	16 (19,46)	31 (27,54)	47
VŠ	5 (7,46)	13 (10,54)	18
celkem	41	58	99

- ▶ odhad pravděpodobnosti, že má matka základní vzdělání:  
 $\hat{P}(vzdel = zakladni) = 34/99$
- ▶ odhad pravděpodobnosti, že jde o plánované těhotenství:  
 $\hat{P}(tehot = plan) = 58/99$
- ▶ **jsou-li** vzdělání a plánovanost **nezávislé**, pak  
 $P((vzdel = zakladni) \cap (tehot = plan))$   
 $= P(vzdel = zakladni) \cdot P(tehot = plan) \doteq (34/99) \cdot (58/99)$
- ▶ očekávaný počet matek se základním vzděláním a plánovaným těhotenstvím (**za platnosti nulové hypotézy**) odhadneme:  
 $99 \cdot (34/99) \cdot (58/99) = 34 \cdot 58/99 \doteq 19,92$

## příklad: souvisí plánované těhotenství se vzděláním?

- ▶ u každé matky zjištovány dva znaky: dosažené vzdělání, zda těhotenství plánováno
  - ▶ základní tabulka
- | vzdělání    | základní  | střední   | VŠ        | celkem |
|-------------|-----------|-----------|-----------|--------|
| neplánováno | 20 (14,1) | 16 (19,5) | 5 (7,5)   | 41     |
| plánováno   | 14 (19,9) | 31 (27,5) | 13 (10,5) | 58     |
| celkem      | 34        | 47        | 18        | 99     |
- ▶ kdyby nebyla závislost, u každého vzdělání by bylo stejné procento plánovaných těhotenství, totiž  $58/99 = 58,6\%$ 
    - ▶ u zákl. vzdělání  $x/34 = 58/99$  tedy  $x = 34 \cdot 58/99 = 19,9$
    - ▶ u středního vzdělání  $x/47 = 58/99$  tedy  $x = 47 \cdot 58/99 = 27,5$
    - ▶ u vysokoškolaček  $x/18 = 58/99$  tedy  $x = 18 \cdot 58/99 = 10,5$
  - ▶ všechny očekávané četnosti jsou dostatečně velké

$$\chi^2 = 6,68 > 5,99 = \chi^2_2(0,05), \quad p = 3,5\%$$

## příklad: plánovaná těhotenství

skutečné četnosti (očekávané četnosti)

vzdělání	plánované		celkem
	ne	ano	
základní	20 (14,08)	14 (19,92)	34
střední	16 (19,46)	31 (27,54)	47
VŠ	5 (7,46)	13 (10,54)	18
celkem	41	58	99

$$\begin{aligned} \chi^2 = & \frac{(20 - 14,08)^2}{14,08} + \frac{(14 - 19,92)^2}{19,92} + \frac{(16 - 19,46)^2}{19,46} + \frac{(31 - 27,54)^2}{27,54} \\ & + \frac{(5 - 7,46)^2}{7,46} + \frac{(13 - 10,54)^2}{10,54} = 6,68 \end{aligned}$$

## příklad: vzdělání snoubenců

ženich	nevěsta			celkem
	základní	střední	VŠ	
základní	24	12	3	39
střední	7	24	3	34
VŠ	3	9	15	27
celkem	34	45	21	100

- ▶ u 100 náhodně vybraných snoubenců bylo zjištěno vzdělání (základní = základní nebo neúplné střední)
- ▶ lze považovat vzdělání snoubenců za nezávislá?
- ▶ jsou četnosti dost velké?
- ▶ nejmenší očekávané četnost (při nezávislosti):  
 $27 \cdot 21/100 = 5,67$

## příklad: vzdělání snoubenců

ženich	nevěsta			celkem
	základní	střední	VŠ	
základní	24 (13,2)	12 (17,6)	3 (8,2)	39
střední	7 (11,6)	24 (15,3)	3 (7,1)	34
VŠ	3 (9,2)	9 (12,2)	15 (5,7)	27
celkem	34	45	21	100

- ▶  $\chi^2 = 43,2 > \chi^2_4(0,05) = 9,5$ ,  $p < 0,1\%$
- ▶ na 5 % hladině jsme prokázali závislost
- ▶ vzdělání snoubenců nelze považovat za nezávislá
- ▶ četnosti na diagonále jsou větší, než očekáváme za nezávislosti
- ▶ četnosti daleko od diagonály (velký rozdíl ve vzdělání) jsou menší, než očekáváme za nezávislosti

12. přednáška 17. prosince

Statistiky (MD360P03Z, MD360P03U) ak. rok 2007/2008

## příklad: předvolební průzkum

- ▶  $\phi > 0$  znamená, že četnosti na hlavní diagonále (indexy 1,1 a 2,2) převládají nad četnostmi na vedlejší diagonále (indexy 1,2 a 2,1)

▶ v našem příkladu

TV XY	strana		celkem
	A	B	
sledoval	11	4	15
nesledoval	6	9	15
celkem	17	13	30

vychází  $\phi = 0,34 > 0$   
(tedy kladné), protože je  $11 \cdot 9 > 6 \cdot 4$

12. přednáška 17. prosince

Statistiky (MD360P03Z, MD360P03U) ak. rok 2007/2008

## čtyřpolní tabulka speciální případ kontingenční tabulky

$a$	$b$	$a + b$
$c$	$d$	$c + d$
$a + c$	$b + d$	$n$

- ▶ sílu závislosti lze měřit  $\phi$ -koeficientem [phi coefficient] (čtyřpolní korelační koeficient)

$$\phi = \frac{ad - bc}{\sqrt{(a+b)(c+d)(a+c)(b+d)}}$$

- ▶  $\phi$  je (jako každý korelační koeficient) mezi  $-1$  a  $1$

11	4	15
6	9	15
17	13	30

- ▶ pro vyjde

$$\phi = \frac{11 \cdot 9 - 4 \cdot 6}{\sqrt{15 \cdot 15 \cdot 17 \cdot 13}} = 0,34$$

12. přednáška 17. prosince

Statistiky (MD360P03Z, MD360P03U) ak. rok 2007/2008

## čtyřpolní tabulka – prokazování závislosti

- ▶ chí-kvadrát porovnávající teoretické a očekávané četnosti lze upravit na tvar

$$\chi^2 = \frac{n(ad - bc)^2}{(a+b)(c+d)(a+c)(b+d)} = n \cdot \phi^2$$

- ▶ nezávislost se na hladině  $\alpha$  zamítá, je-li  $\chi^2 \geq \chi^2_1(\alpha)$
- ▶ příklad (předvolební průzkum)

$$\chi^2 = \frac{30 \cdot (11 \cdot 9 - 4 \cdot 6)^2}{15 \cdot 15 \cdot 17 \cdot 13} = 3,39 = 30 \cdot 0,34^2$$

- ▶ závislost jsme na 5% hladině neprokázali, neboť

$$3,39 < 3,84 = \chi^2_1(0,05), \quad p = 6,5\%$$

12. přednáška 17. prosince

Statistiky (MD360P03Z, MD360P03U) ak. rok 2007/2008

12. přednáška 17. prosince

Statistiky (MD360P03Z, MD360P03U) ak. rok 2007/2008

## malé očekávané četnosti ve čtyřpolní tabulce

- stále je třeba, aby byly očekávané četnosti dost velké ( $\geq 5$ )
- **Yatesova korekce** umožní rozhodnutí i při menších četnostech tím, že zmenší čitatele

$$\chi^2_{\text{Yates}} = \frac{n(|ad - bc| - n/2)^2}{(a+b)(c+d)(a+c)(b+d)}$$

- nezávislost se zamítá, je-li opět  $\chi^2_{\text{Yates}} \geq \chi^2_1(\alpha)$
- **Fisherův exaktní test** počítá přímo  $p$ -hodnotu

## příklad: souvislost délky kojení a plánování těhotenství

těhot.	Praha a venkov			venkov		
	neplán.	plán.	celkem	neplán.	plán.	celkem
ve 24. t. nekojí	35	36	71	13	9	22
ve 24. t. koji	6	22	28	1	6	7
celkem	41	58	99	14	15	29

- bez ohledu na místo:  $\chi^2 = 6,43$ ,  $p = 1,1\%$ ,  $\chi^2_{\text{Yates}} = 5,33$ ,  $p = 2,1\%$  (nejm. četnost  $41 \cdot 28/99 = 11,6$ ) Fisherův exaktní test:  $p = 1,3\%$
- venkov:  $\chi^2 = 4,27$ ,  $p = 3,9\%$ ,  $\chi^2_{\text{Yates}} = 2,66$ ,  $p = 10,3\%$  (nejm. četnost  $14 \cdot 7/29 = 3,4$ ) Fisherův exaktní test:  $p = 8,0\%$

## Simpsonův paradox

dílčí tabulky mohou ukazovat na závislost jiného směru, než jejich součet

venkov	A	B	celkem
sledoval	34	5	39
nesledoval	28	2	30
celkem	62	7	69

město	A	B	celkem
sledoval	4	29	33
nesledoval	6	35	42
celkem	10	64	74

$$\phi_{\text{venkov}} = -0,10$$

$$\phi_{\text{město}} = -0,04$$

celkem	A	B	celkem
sledoval	38	34	72
nesledoval	34	37	71
celkem	72	71	143

$$\phi_{\text{celkem}} = 0,05$$

- po spojení dvou tabulek se záporným  $\phi$ -koeficientem vyšla tabulka s kladným  $\phi$ -koeficientem

## závislost mezi nula-jedničkovým a kvantitativním znakem

- dva nezávislé výběry, např. hoši  $X_1, \dots, X_{n_0}$  a dívky  $X_{n_0+1}, \dots, X_{n_0+n_1}$ , vždy normální rozdělení jako pro dvouvýběrový t-test
- otázka: jak silně souvisí sledovaná vlastnost a pohlaví?
- označme pohlaví formálně  $Y_i = 0$  pro chlapce a  $Y_i = 1$  pro dívčata
- korelační koeficient  $r_{X,Y}$  mezi těmito veličinami se dá zapsat také jako

$$r_{\text{bis}} = \frac{\bar{X}_1 - \bar{X}_0}{S} \sqrt{\frac{n_0 n_1}{n(n-1)}}$$

- $S$  je směrodatná odchylka spočítaná bez ohledu na pohlaví,  $n = n_0 + n_1$  je celkový počet měření v obou výběrech
- $r_{\text{bis}}$  **bodově-biseriální korelační koeficient**

## příklad: výška desetiletých

- ▶ stejná data jako dvouvýběrový test (data ze str. 170)

$$\bar{X}_0 = 139,13, \quad n_0 = 15$$

$$\bar{X}_1 = 140,83, \quad n_1 = 12$$

$$S^2 = 38,18, \quad S = 6,18$$

▶

$$r_{\text{bis}} = \frac{140,83 - 139,13}{6,18} \sqrt{\frac{15 \cdot 12}{15 + 12}} = 0,493$$

- ▶  $H_0$  : nezávislost

- ▶ má-li  $X$  normální rozdělení, lze použít stejný test, jako u korelačního koeficientu; je to ekvivalentní dvouvýběrovému  $t$ -testu (při stejných populačních rozptylech)

## přehled korelačních koeficientů

- ▶ základním je (momentový) Pearsonův

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

- ▶ když místo hodnot  $x_i, y_i$  dosadíme jejich pořadí  $R_i, Q_i$ , dostaneme (pořadový) Spearmanův korelační koeficient

$$r_S = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ je-li jedna z veličin nula-jedničková, vyjde bodově-biseriální korelační koeficient  $r_{\text{bis}}$
- ▶ jsou-li obě veličiny nula-jedničkové, dostaneme  $\phi$ -koeficient (čtyřpolní korelační koeficient)

## přehled testů o populačních mírách polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián
jeden výběr	jednovýběrový $t$ -test	znaménkový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney