

Přednáška 9 – Testy nezávislosti

Budeme testovat, zda jsou dva výběry nezávislé

Testy pro spojitá data

Testy pro diskrétní data

Parametrické testy
s předpokladem
normality

Neparametrické testy
bez předpokladu
normality

Nulová a alternativní hypotézy pro všechny testy nezávislosti:

H_0 : veličiny jsou nezávislé

H_A : veličiny nejsou nezávislé

- Směr testu nevolíme
- Tabulka testů hypotéz:

<http://staff.utia.cas.cz/uglickich/pdfka/volbaTH.pdf>

Použijeme za předpokladu:

- 2 párové spojité výběry
- normalita všech výběrů

• Pearsonův korelační koeficient – míra **korelace**

- $0 < r_p \leq 1$ – **přímá závislost**
- $-1 \leq r_p < 0$ – **nepřímá závislost**
- pro nezávislé veličiny $r_p = 0$

Nulová hypotéza Pearsonova testu:

$H_0 : r_p = 0$ veličiny jsou **lineárně nezávislé**

Alternativní hypotéza – opačné tvrzení:

$H_A : r_p \neq 0$ veličiny **nejsou lineárně nezávislé**

$$T = \frac{r_p}{\sqrt{\frac{1-r_p^2}{n-2}}} \sim \text{Studentovo rozdělení}$$

Příklad: lineární závislost mezi plochou bytu a jeho cenou

- čím větší je byt, tím je dražší?
- závislost **nemusí** být nutně lineární
- oba párové výběry – normální

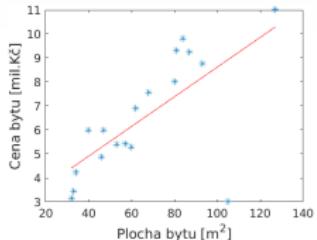
Nulová hypotéza:

H_0 : plocha a cena jsou lineárně nezávislé

Alternativní hypotéza:

H_A : nejsou lineárně nezávislé

- p-hodnota = 0.0018 < 0.05
- $r_p = 0.68$ – čím větší je byt, tím je dražší
- data jsou vhodná k lineární regresi



plocha, m ²	cena, Kč
84	9 811 200
105	3 000 000
40	5 990 000
57	5 420 000
127	11 000 000
80	8 000 000
32	3 150 000
46	4 876 000
33	3 450 000
93	8 754 000
34	4 249 929
53	5 400 000
87	9 240 250
47	5 988 050
81	9 296 600
60	5 280 000
62	6 894 250
68	7 566 600

Použijeme za předpokladu:

- 2 párové spojité výběry
- alespoň 1 výběr nemá normalitu

Spearmanův koeficient pořadové korelace

- na základě Pearsonova koeficientu
- s využitím pořadí hodnot výběrů místo dat:

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}, \quad r_s \in (-1, 1)$$

- d_i – rozdíly pořadí z výběrů

- $0 < r_s \leq 1$ – přímá závislost
- $-1 \leq r_s < 0$ – nepřímá závislost
- pro nezávislé veličiny $r_s = 0$

Nulová hypotéza Spearanova testu:

$H_0 : r_s = 0$ veličiny jsou nezávislé

Alternativní hypotéza – opačné tvrzení:

$H_A : r_s \neq 0$ veličiny nejsou nezávislé

Příklad: závislost mezi dobou strávenou u obrazovky mobilu a denním počtem kroků

- oba párové výběry nejsou normální

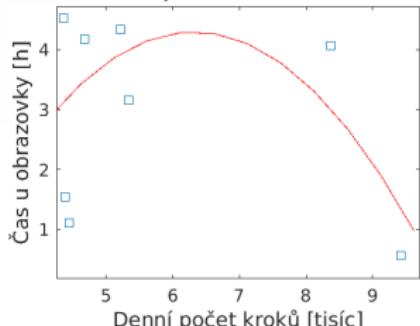
Nulová hypotéza:

H_0 : počet kroků a doba jsou nezávislé

Alternativní hypotéza:

H_A : nejsou nezávislé

- p-hodnota je $0.03 < 0.05$
- data jsou vhodná k regresi (polynomiální, exponenciální, atd.)



denní počet kroků	čas, [h]
8374.6163	4.07
9419.2094	0.57
4364.4742	4.53
4682.0057	4.18
9885.3437	0.54
5214.719	4.34
4119.8086	4.57
4446.0034	1.11
5337.3764	3.16
4384.4456	1.54

Pro zajímavost:

Pearsonův test:

- p-hodnota je 0.1263
- data nejsou vhodná k lineární regresi

Testy nezávislosti pro diskrétní veličiny

χ^2 test nezávislosti

Předpoklady:

- 2 **diskrétní** veličiny
- všechny četnosti > 2 , aspoň 80% četností > 5
- kontingenční tabulka

$$T = \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i}$$

- O_i – pozorované četnosti (data)
- E_i – očekávané četnosti (v případě nezávislosti)

Nulová hypotéza H_0 :

veličiny jsou **nezávislé**

Alternativní hypotéza H_A :

veličiny **nejsou nezávislé**

Příklad: Ptali jsme se zákazníků různých věkových kategorií, v jakém e-shopu nejraději objednávají potraviny. Mezi zákazníky ve věku od 20 do 30 let preferovalo 56 e-shop A, 42 B a 19 C. Ve věku 31-45 let 46 zákazníků volilo e-shop A, 17 B a 37 využívalo služeb rozvozu potravin C. Z věkové kategorie od 46 do 70 let 25 zákazníků by si objednalo potraviny v e-shopu A, 36 v B a 44 v C. Ha hladině významnosti 0.05 testujte tvrzení, že věk a volba e-shopu jsou nezávislé.

- 2 diskrétní veličiny:

$věk \in \{20\text{-}30 \text{ let}, 31\text{-}45 \text{ let}, 46\text{-}70 \text{ let}\}$, $e\text{-shop} \in \{A, B, C\}$

- kontingenční tabulka – O

věk \ e-shop	A	B	C
20-30 let	56	42	19
31-45 let	46	17	37
46-70 let	25	36	44

Princip výpočtu E :

- $\frac{O}{n} = f(věk, e\text{-shop})$
- Pokud platí
 $f(věk, e\text{-shop}) = f(věk)f(e\text{-shop})$
 veličiny jsou nezávislé
- $f(věk) \cdot f(e\text{-shop}) \cdot n = E$

Postup:

$$\textcircled{1} \quad \frac{O}{332} = f(věk, e\text{-shop}) - \text{sdružené rozdělení}$$

věk \ e-shop	A	B	C
20-30 let	0.17	0.13	0.06
31-45 let	0.14	0.05	0.11
46-70 let	0.08	0.11	0.15

2 marginální rozdělení $f(\text{věk})$ a $f(\text{e-shop})$

e-shop \ věk	A	B	C	$f(\text{věk})$
20-30 let	0.17	0.13	0.06	$0.17+0.13+0.06=0.36$
31-45 let	0.14	0.05	0.11	$0.14+0.05+0.11=0.3$
46-70 let	0.08	0.11	0.15	$0.08+0.11+0.15=0.34$
$f(\text{e-shop})$	0.39	0.29	0.32	

3

$f(\text{věk}) \cdot f(\text{e-shop}) =$ nové sdružené rozdělení pro nezávislé veličiny:

$$f(\text{věk}) \cdot f(\text{e-shop}) =$$

věk \ e-shop	A	B	C
20-30 let	0.14	0.1	0.12
31-45 let	0.12	0.09	0.09
46-70 let	0.13	0.1	0.11

④ $f(\text{věk}) \cdot f(\text{e-shop}) \cdot 332 = E$

věk \ e-shop	A	B	C
20-30 let	47	33	40
31-45 let	40	30	30
46-70 let	43	33	37

- p-hodnota = 0.0000033
- zamítáme H_0 , že věk zákazníků a výběr e-shopu jsou nezávislé

Fisherův exaktní test

Předpoklady:

- nominální binární data
- kontingenční tabulka 2×2

X \ Y	$Y = 1$	$Y = 2$
$X = 1$	a	b
$X = 2$	c	d

Nulová hypotéza H_0 :

veličiny jsou nezávislé

Příklad:

		operační systém	
		A	B
pohlaví	muži	19	26
	ženy	31	22

- operační systém $\in \{A, B\}$, pohlaví $\in \{\text{muži}, \text{ženy}\}$
- p-hodnota = 0.1555

$$\begin{aligned} p^* &= \frac{\binom{a+c}{a} \binom{b+d}{b}}{\binom{n}{a+b}} \\ &= \frac{(a+b)! (a+c)! (c+d)! (b+d)!}{n! a! b! c! d!} \end{aligned}$$

- p^* – referenční pravděpodobnost

Alternativní hypotéza H_A :

veličiny nejsou nezávislé

Gamma koeficient (Goodmanovo-Kruskalovo gamma)

Předpoklady:

- ordinální kategorická data

Nulová hypotéza H_0 :

$\gamma = 0$ veličiny jsou nezávislé

Alternativní hypotéza H_A :

$\gamma \neq 0$ veličiny nejsou nezávislé

- míra asociace mezi veličinami

$$\gamma = \frac{N_c - N_d}{N_c + N_d}, \quad \gamma \in \langle -1, 1 \rangle$$

- N_c – počet dat s přímou závislostí
- N_d – počet dat s nepřímou závislostí

- $0 < \gamma \leq 1$ – přímá závislost
- $-1 \leq \gamma < 0$ – nepřímá závislost
- pro nezávislé veličiny $\gamma = 0$

$$T = \gamma \sqrt{\frac{N_c + N_d}{n(1 - \gamma^2)}}$$

Příklad: vazba mezi vzděláním a dobou po získání řidičského průkazu

vzdělání doba	bez maturity	s maturitou	VŠ
do 5 let	25	38	11
6-10 let	56	47	37
více než 10 let	53	46	54

- **doba** $\in \{\text{do 5 let}, \text{ 6-10 let}, \text{ více než 10 let}\}$
- **vzdělání** $\in \{\text{bez maturity}, \text{ s maturitou}, \text{ VŠ}\}$
- uspořádaná data v souladu pro obě veličiny
- **hlavní** diagonála – přímá vazba (“vyšší vzdělání – déle mám řidičák”)
- **vedlejší** diagonála – nepřímá vazba

$$N_c = 25 * (47 + 37 + 46 + 54) + 38 * (37 + 54) + 11 * 0 + 56 * (46 + 54) + 47 * 54 + 37 * 0 + 53 * 0 + 46 * 0 + 54 * 0 = 16196$$

$$N_d = 11 * (56 + 47 + 53 + 46) + 38 * (56 + 53) + 25 * 0 + 37 * (53 + 46) + 47 * 53 + 56 * 0 + 54 * 0 + 46 * 0 + 53 * 0 = 12518$$

$$\bullet \gamma = \frac{16196 - 12518}{16196 + 12518} = 0.128$$

$$\bullet \text{p-hodnota} = 0.0592$$

Yule's Q koeficient – speciální případ Gamma koeficientu

Předpoklady:

- ordinální binární data
- kontingenční tabulka 2×2

		$Y = 1$	$Y = 2$
$X = 1$	a	b	
$X = 2$	c	d	

$$Q = \frac{N_c - N_d}{N_c + N_d} = \frac{ad - bc}{ad + bc}$$

- H_0 , H_A , T – stejné

Příklad: závislost mezi dobou učení a výsledkem u zkoušky

		prospěch	neprospěl	prospěl
		málo se učil/a	13	5
doba učení		hodně se učil/a	7	19

- $Q = \frac{13*19 - 7*5}{13*19 + 7*5} = 0.752$
- p-hodnota = 4.8866e-07