

Testy pro jeden výběr

Testy pro dva výběry

- dotazníky – nehody, okolnosti nehody, aj.

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

Test podílu pro jeden výběr

- alternativní rozdělení, $x \in \{0,1\}$, 0 – neúspěch, 1 – úspěch
- výběrový podíl $p = \frac{\text{počet úspěchů}}{\text{počet dat}}$ Příklad: podíl studentů s modrýma očima

Předpoklady:

- $n > 30$
- $np \geq 5, n(1 - p) \geq 5$

- $np = 100 \cdot 0.2 = 20 > 5$ – můžeme použít test
- $np = 100 \cdot 0.8 = 80 > 5$ – můžeme použít test
- $np = 1000 \cdot 0.0001 = 0.1 < 5$ – nemůžeme

Nulová hypotéza:

$H_0 : p = p_0$ podíl se rovná předpokládané hodnotě

$$T = \frac{p - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \sim N(0, 1) \text{ approximativně pro } n > 30$$

Alternativní hypotéza:

$H_A : p \neq (>, <)p_0$
určuje směr testu

Příklad: Na úseku silnice s maximální povolenou rychlostí 80 km/h kontrolujeme rychlosť vozidel. Testujeme hypotézu, že podíl řidičů, kteří překračují rychlosť o více než 3km, je menší než 20%.

78	86	65	93	92	85	76	79	...	→ $n > 30$
----	----	----	----	----	----	----	----	-----	------------

- diskrétní N.V. – **překročení povolené rychlosti** o více než 3 km/h
- **úspěch** – rychlosť > 83 , **neúspěch** – rychlosť ≤ 83
- jeden výběr, testujeme **podíl**

Nulová hypotéza – podle tvrzení

$H_0 : p=0.2$ (nebo $p<0.2$) – podíl řidičů překračujících rychlosť o více než 3 km/h se rovná nebo je menší než 0.2

Alternativní hypotéza – opačné tvrzení

$H_A : p>0.2$ – podíl je větší než 0.2 – **pravostranný** test

$$p = \frac{\text{počet úspěchů}}{\text{počet dat}} = \frac{\text{počet rychlosťí} > 83}{\text{počet řidičů}} = \frac{1(86)+1(93)+1(92)+1(85)+...}{n}$$

χ^2 test dobré shody

- test rozdělení výběru
- diskrétní rozdělení

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

- O_i – pozorované četnosti
- E_i – očekávané četnosti
- pouze pravostranný

Nulová a alternativní hypotézy:

H_0 : data mají teoretické rozdělení

H_A : data nemají teoretické rozdělení

Předpoklady:

- všechny četnosti > 2
- aspoň 80% četností > 5

Příklad: Sít' autorizovaných prodejců vozů nabízí vozy značky ABC s následujícími typy karoserie: hatchback, sedan, kombi a coupé.

Doposud vozy se prodávaly takto:


kombi 62%, hatchback 18%, sedan 12%, coupé 8%.

V rámci rozšíření sítě byla otevřena nová pobočka s autorizovaným prodejcem, kde se zatím prodalo 120 vozů s karoserií kombi, 40 vozů hatchback, 18 sedanů a 22 coupé. Zajímá nás, zda se prodej na nové pobočce neliší od ostatních prodejců.

- diskrétní N.V. $\text{prodej} \in \{\text{kombi, hatchback, sedan, coupé}\}$

- je dáno teoretické rozdělení – pf $f(\text{prodej})$

	kombi	hatchback	sedan	coupé
$f(\text{prodej})$	0.62	0.18	0.12	0.08



Nulová hypotéza:

H_0 : prodej na nové pobočce má stejné rozdělení

Alternativní hypotéza:

H_A : nemá stejné rozdělení

- pozorované četnosti $O = [120 \quad 40 \quad 18 \quad 22]$

- očekávané četnosti (v případě shody rozdělení):

$$E = [0.62 \cdot 200 \quad 0.18 \cdot 200 \quad 0.12 \cdot 200 \quad 0.08 \cdot 200] = [124 \quad 36 \quad 24 \quad 16]$$

- p-hodnota = 0.2286

Test o shodě dvou podílů

- dva výběry
- dvě diskrétní N.V. $x, y \in \{0,1\}$, 0 – neúspěch, 1 – úspěch
- výběry nemusí být párové
- stejné předpoklady jako pro test podílu

Nulová hypotéza:

$H_0 : p_1 = p_2$ podíly jsou stejné

Alternativní hypotéza:

$H_A : p_1 \neq (>, <)p_2$ určuje směr testu

$$T = \frac{p_1 - p_2}{\sqrt{p(1-p)\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \sim N(0, 1), \text{ kde } p = \frac{p_1 n_1 + p_2 n_2}{n_1 + n_2}$$

Příklad: Policie ČR tvrdí, že na silnici s maximální povolenou rychlostí 80 km/h směrem z Prahy je menší podíl řidičů překračujících povolenou rychlosť než směrem do Prahy. Testujeme tvrzení policie na hladině významnosti 0.05.

z Prahy	93	86	85	93	92	85	86	79	... → $n_1 > 30$
do Prahy	78	96	75	83	97	105	81	79	... → $n_2 > 30$

- 2 diskrétní N.V. : překročení rychlosti na silnici z Prahy
překročení rychlosti na silnici do Prahy
- úspěch – rychlosť > 80, neúspěch – rychlosť ≤ 80
- dva výběry, testujeme shodu podílů

Nulová hypotéza – podle tvrzení

$H_0 : p_z = p_{do}$ (nebo $p_z < p_{do}$) – podíl řidičů překračujících povolenou rychlosť na silnici směrem z Prahy je menší než směrem do Prahy

Alternativní hypotéza – opačné tvrzení

$H_A : p_z > p_{do}$ – pravostranný test

Dva výběrové podíly:

$$p_z = \frac{\text{rychlosti z Prahy} > 80}{n_1} = \frac{1(93)+1(86)+1(85)+1(93)+1(92)+1(85)+\dots}{n_1}$$

$$p_{do} = \frac{\text{rychlosti do Prahy} > 80}{n_2} = \frac{1(96)+1(83)+1(97)+1(105)+1(81)+\dots}{n_2}$$

McNemarův test

Předpoklady:

- dva párové diskrétní výběry
- binární data
- kontingenční tabulka 2×2
- pouze pravostranný

- testování efektu nějaké události
- shoda četností **před** a **po** – změna?

		po	NE	ANO
před	NE	a	b	
	ANO	c	d	

Nulová hypotéza:

$H_0 : b = c$ četnosti jsou stejné, tj., není žádná změna

Alternativní hypotéza:

$H_A : b \neq c$ četnosti nejsou stejné, tj., je změna

$$T = \frac{(b-c)^2}{b+c} \sim \chi^2\text{-rozdělení}$$

Příklad: Na přechodu pro chodce namontovali nový semafor.

Zeptali jsme se 15 lidí na jejich spokojenost s přechodem před instalací semaforu a po instalaci. Testujeme tvrzení, že instalace semaforu nepřispěla ke spokojenosti občanů.

před instalací	1	1	1	2	1	1	2	1	1	1	1	1	1	1	1
po instalaci	1	2	1	2	2	2	2	2	1	2	2	2	1	2	2

- diskrétní N.V.
 $\text{spokojenost} \in \{1=\text{NE}, 2=\text{ANO}\}$
- párové výběry
- změna stavu: četnosti b, c

• kontingenční tabulka:

		po	NE	ANO
před	NE	a=4	b=9	
	ANO	c=0	d=2	

Nulová hypotéza:

$H_0 : b = c$ spokojenost respondentů je stejná před instalací semaforu a po ní, tj., semafor nemá vliv

Alternativní hypotéza:

$H_A : b \neq c$ semafor má vliv

• p-hodnota = 0.0026998 < 0.05

Poznámka 1:

- Testy pro dva výběry – testy nezávislosti pro diskrétní data
 - χ^2 test nezávislosti
 - Fisherův exaktní test
 - Gamma koeficient
 - Yule's Q koeficient

Poznámka 2:

- poslední přednáška
- příští tyden – konzultace podle domluvy ([konkrétní dotazy](#))
- zkouška, termíny