

# Biostatistika



Opakování  
Analýza kontingenčních tabulek  
Základy korelační analýzy


# Co byste měli umět z minula:



1. Určit, kdy je vhodné použít pro testování hypotéz parametrické a neparametrické testy – ověřování předpokladů.
2. Vybrat typ neparametrického testu – jednovýběrový, párový nebo dvouvýběrový?
3. Provést testování v softwaru Statistica – Wilcoxonův test, znaménkový test, Mannův-Whitneyho test, Kruskalův-Wallisův test.
4. Interpretovat výsledky testování.

# Základní rozhodování o výběru statistických testů

## - co budeme probírat dnes



# Analýza kontingenčních tabulek



Kontingenční tabulky

Pearsonův chí-kvadrát test (test dobré shody)

Fisherův exaktní test

McNemarův test

# Kontingenční tabulka - opakování



- Frekvenční summarizace dvou kategoriálních proměnných (binárních, nominálních nebo ordinálních proměnných).
- Obecně: **R x C kontingenční tabulka** (R – počet kategorií jedné proměnné, C – počet kategorií druhé proměnné).
- Speciální případ: 2 x 2 tabulka = čtyřpolní tabulka.
- Kontingenční tabulky: **absolutních četností, celkových procent, řádkových/sloupcových četností**
- Př.: Sumarizace vyšetřených osob podle pohlaví a výsledku diagnostického testu.

Pohlaví	Výsledek vyšetření		Celkem
	Nemocný	Zdravý	
Muž	45	11	56
Žena	25	6	31
Celkem	70	17	87

# Ukázka kontingenční tabulky

- Vztah pohlaví a výskytu onemocnění (pozor na hodnocení nesmyslného vztahu)

	Nemocný	Zdravý	Celkem	
Muž	a	b	$a + b$	Marginální absolutní četnost
Žena	c	d	$c + d$	
Celkem	$a + c$	$b + d$	$a + b + c + d = N$	Celkový počet hodnot
				Simultánní absolutní četnost

↓

	Nemocný	Zdravý	Celkem
Muž	45	11	56
Žena	25	6	31
Celkem	70	17	87



Jsou více nemocní muži nebo ženy?

# Kontingenční tabulky – procenta



Kontingenční tabulka absolutních četností

Skupina	Věk				Celkem
	<60 let	60-70 let	70-80 let	≥80 let	
CN	1	7	176	46	230
MCI	13	85	201	107	406
AD	9	34	90	64	197
Celkem	23	126	467	217	833

Kontingenční tabulka řádkových procent

Skupina	Věk				Celkem
	<60 let	60-70 let	70-80 let	≥80 let	
CN	0,4	3,0	76,5	20,0	100,0
MCI	3,2	20,9	49,5	26,4	100,0
AD	4,6	17,3	45,7	32,5	100,0
Celkem	2,8	15,1	56,1	26,1	100,0

Kontingenční tabulka sloupcových procent

Skupina	Věk				Celkem
	<60 let	60-70 let	70-80 let	≥80 let	
CN	4,3	5,6	37,7	21,2	27,6
MCI	56,5	67,5	43,0	49,3	48,7
AD	39,1	27,0	19,3	29,5	23,6
Celkem	100,0	100,0	100,0	100,0	100,0

Kontingenční tabulka celkových procent


Skupina	Věk				Celkem
	<60 let	60-70 let	70-80 let	≥80 let	
CN	0,1	0,8	21,1	5,5	27,6
MCI	1,6	10,2	24,1	12,8	48,7
AD	1,1	4,1	10,8	7,7	23,6
Celkem	2,8	15,1	56,1	26,1	100,0

# Kontingenční tabulky – popis a vizualizace



Skupina	Věk				Celkem
	<60 let	60-70 let	70-80 let	≥80 let	
CN	1 (0,4%)	7 (3,0%)	176 (76,5%)	46 (20,0%)	230 (100,0%)
MCI	13 (3,2%)	85 (20,9%)	201 (49,5%)	107 (26,4%)	406 (100,0%)
AD	9 (4,6%)	34 (17,3%)	90 (45,7%)	64 (32,5%)	197 (100,0%)
Celkem	23 (2,8%)	126 (15,1%)	467 (56,1%)	217 (26,1%)	833 (100,0%)

Skupina:



Věk:  <60 let  60-70 let  70-80 let  ≥80 let

# Co analyzujeme u kontingenčních tabulek?



- Analýza kontingenčních tabulek umožňuje analyzovat **vazbu mezi dvěma kategoriálními proměnnými**. Základním způsobem testování je tzv. chí-kvadrát test, který **srovnává pozorované četnosti kombinací kategorií oproti očekávaným četnostem**, které vychází z teoretické situace, kdy je vztah mezi proměnnými náhodný.
- Test dobré shody je využíván také pro **srovnání pozorovaných četností proti očekávaným četnostem daných určitým pravidlem** (typickým příkladem je Hardy-Weinbergova rovnováha v genetice).
- Specifickým typem výstupů odvozených z kontingenčních tabulek jsou tzv. **poměry šancí a relativní rizika**, využívaná často v medicíně pro identifikaci a popis rizikových skupin pacientů.

# Test dobré shody - základní teorie

Testová statistika:

$$\chi^2 = \sum \frac{\left[ \frac{\text{pozorovaná četnost} - \text{očekávaná četnost}}{\text{očekávaná četnost}} \right]^2}{\text{očekávaná četnost}}$$


$$\chi^2 = \underbrace{\frac{\left[ \frac{\text{pozorovaná četnost} - \text{očekávaná četnost}}{\text{očekávaná četnost}} \right]^2}{\text{očekávaná četnost}}}_{\text{1. jev}} + \underbrace{\frac{\left[ \frac{\text{pozorovaná četnost} - \text{očekávaná četnost}}{\text{očekávaná četnost}} \right]^2}{\text{očekávaná četnost}}}_{\text{2. jev}} + \dots$$

$$\chi^2 > \chi^2_{(1-\alpha)} (\text{s.v.})$$

1 - hladina významnosti

stupně volnosti

... zamítáme  $H_0$



# Test dobré shody: příklad I

$$\chi^2_{(1)} = \frac{\left[ \frac{\text{pozorovaná četnost} - \text{očekávaná četnost}}{\text{očekávaná četnost}} \right]^2}{\text{očekávaná četnost}} + \frac{\left[ \frac{\text{pozorovaná četnost} - \text{očekávaná četnost}}{\text{očekávaná četnost}} \right]^2}{\text{očekávaná četnost}}$$

I. jev 1                                    II. jev 2

## Příklad



10 000 lidí hází mincí

- rub: 4 000 případů (R)
- líc: 6 000 případů (L)



Lze výsledek považovat za statisticky významně odlišný (nebo neodlišný) od očekávaného poměru R : L = 1 : 1 (tzn. že je výsledek hodu mincí náhodný)?

$$\chi^2 = \frac{(4000 - 5000)^2}{5000} + \frac{(6000 - 5000)^2}{5000} = 400$$

Tabulková hodnota:  $\chi^2_{(0,95)} (\nu = k - 1 = 1) = 3,84 \quad (0,95 = 1 - \alpha)$



**Rozdíl je vysoce statisticky významný ( $p < 0,001$ )**

# Test dobré shody: příklad II




Celkem bylo zkoumáno 250 semen určitého druhu rostliny a roztríděno do následujících kategorií: žluté/hladké; žluté/vrásčité; zelené/hladké; zelené/vrásčité. Předpokládaný poměr výskytu těchto kategorií v populaci je **9 : 3 : 3 : 1**. Následující tabulka obsahuje původní data z pozorování a dále postup při testování  $H_0$ .

	žluté/hladké	žluté/vrásčité	zelené/hladké	zelené/vrásčité	n
f poz.	152	39	53	6	250
f oček.	140,6250	46,8750	46,8750	15,6250	

$$\nu = k - 1 = 3$$

$$\chi^2 = \frac{11,3750^2}{140,6250} + \frac{7,8750^2}{46,8750} + \frac{6,1250^2}{46,8750} + \frac{9,6250^2}{15,6250} = 8,972$$

$$\text{Tabulková hodnota: } \chi_{(0,95)}^2 (\nu = k - 1 = 3) = \underline{7,81} \quad (0,95 = 1 - \alpha)$$




Zamítáme hypotézu shody pozorovaných četností s očekávanými

# Kontingenční tabulka - hypotézy



- **NEZÁVISLOST** (Pearsonův chí-kvadrát test, Fisherův exaktní test)
  - Jeden výběr, 2 charakteristiky – obdoba nepárového uspořádání
  - Např.: existence vztahu mezi barvou očí a známkou z biostatistiky u studentů
- **SHODA STRUKTURY** (Pearsonův chí-kvadrát test, Fisherův exaktní test)
  - Tzv. test homogeneity
  - Více výběrů, jedna charakteristika – obdoba nepárového uspořádání
  - Např.: pohlaví pacientů s diabetem v  $K$  nemocnicích (tj.  $K$  výběrů)
- **SYMETRIE** (McNemarův test)
  - Jeden výběr, opakovaně jedna charakteristika – obdoba párového uspořádání
  - Např.: posouzení stavu stromů ve dvou sezónách

# Základní rozhodování o výběru statistických testů - analýza kontingenčních tabulek



# Kontingenční tabulka - obecně



- Máme dvě nominální veličiny, X (má r variant) a Y (má s variant)
- Kontingenční tabulka typu  $r \times s$

$x_{[j]}$	$y_{[k]}$	$y_{[1]}$	.....	.....	$y_{[s]}$	$n_j.$
$x_{[1]}$		$n_{11}$	.....	.....	$n_{1s}$	$n_{1.}$
.		.	.....	.....	.	.
.		.	.....	.....	.	.
$x_{[r]}$		$n_{r1}$	.....	.....	$n_{rs}$	$n_r.$
$n_{.k}$		$n_{.1}$	.	.	$n_{.s}$	$n$

Marginální absolutní četnost

Marginální absolutní četnost

Simultánní absolutní četnost

- Označení:
  - $n_{jk}$ - simultánní absolutní četnost,
  - $n_{j.}$ - marginální absolutní četnost

# Testování nezávislosti – Pearsonův chí-kvadrát test



- Souvisí spolu výskyt dvou nominálních znaků měřených na jediném výběru?
- Příklad: Souvisí barva očí (modrá, zelená, hnědá) a barva vlasů (hnědá, černá, blond) u vybraných 30 studentů?
- **Nulová hypotéza:** Znaky X a Y jsou nezávislé náhodné veličiny.
- **Alternativní hypotéza:** Znaky X a Y jsou závislé náhodné veličiny.
- Test: **Pearsonův chí-kvadrát**

$$K = \sum_{j=1}^r \sum_{k=1}^s \frac{(n_{jk} - e_{jk})^2}{e_{jk}} \quad \text{H}_0 \text{ platí} \quad \approx \quad \chi^2((r-1)(s-1))$$

Očekávané (teoretické) četnosti  $e_{jk}$ :  $e_{jk} = \frac{n_j \cdot n_k}{n}$

- $H_0$  zamítáme na hladině významnosti  $\alpha$ , pokud  $K \geq \chi^2_{1-\alpha}((r-1)(s-1))$
- **Předpoklady testu ?**

# Testování nezávislosti – Pearsonův chí-kvadrát test



- **Předpoklady Pearsonova chí-kvadrát testu:**

1. **Jednotlivá pozorování** shrnutá v kontingenční tabulce **jsou nezávislá**, tj. každý prvek patří jen do jedné buňky kont. tabulky, nemůže zároveň patřit do dvou.
  2. **Podmínky dobré approximace:** Očekávané (teoretické) četnosti jsou aspoň v 80 % případů větší nebo rovné 5 a ve 100 % případů nesmí být pod 2 (pokud není tento předpoklad splněn, je vhodné sloučit kategorie s nízkými četnostmi, ale tyto kategorie musí být slučitelné!).
- **Měření síly závislosti:**

Cramérův koeficient:  $V = \sqrt{\frac{K}{n(m-1)}},$  kde  $m = \min\{r, s\}, V$  je z intervalu  $(0,1)$

Význam hodnot: 0-0,1....zanedbatelná závislost

0,1-0,3...slabá závislost

0,3-0,7...střední závislost

0,7-1 silná závislost

# Testování nezávislosti – Pearsonův chí-kvadrát test



- **Podmínka dobré aproximace – alespoň 80% buněk musí mít očekávanou (teoretickou) četnost větší než 5 – pro různě velké tabulky:**

tabulka 2x3 či 3x2 – alespoň 5 z 6 buněk

tabulka 2x4 či 4x2 – alespoň 7 z 8 buněk

tabulka 2x5 či 5x2 – alespoň 8 z 10 buněk

tabulka 3x3 – alespoň 8 z 9 buněk

tabulka 3x4 či 4x3 – alespoň 10 z 12 buněk

tabulka 3x5 či 5x3 – alespoň 12 z 15 buněk

tabulka 4x4 – alespoň 13 z 16 buněk

tabulka 4x5 či 5x4 – alespoň 16 z 20 buněk

tabulka 5x5 – alespoň 20 z 25 buněk

# Kontingenční tabulky: příklad

gen \ †	Ano	Ne	$\Sigma$
Ano	20	82	102
Ne	10	54	64
$\Sigma$	30	136	166

$$F_A = 102 * 30 / 166 = 18,43$$


$$F_B = 102 * 136 / 166 = 83,57$$

$$F_C = 11,57$$


$$F_D = 52,43$$

$$\chi^2_{(1)} = \frac{(20 - 18,43)^2}{18,43} + \frac{(82 - 83,57)^2}{83,57} + \frac{(10 - 11,57)^2}{11,57} + \frac{(54 - 52,43)^2}{52,43} = 0,423 \quad 0,423 < \chi^2_{0,95}{}^{(1)} = 3,84$$


## Kontingenční tabulka v obrázku



Gen: ANO



Gen: NE



# Řešení v softwaru Statistica



- Datový soubor může být zadán 2 způsoby:
  - **Původní data** (co řádek, to subjekt charakterizovaný danými kategoriálními proměnnými),
  - **Agregovaná data** (kontingenční tabulka, četnosti všech kombinací kategorií 2 kategoriálních proměnných) – analýza agregovaných dat možná i pomocí webových kalkulátorů.

# Způsob 1: Řešení v softwaru Statistica I

- Na hladině významnosti 0,05 testujte hypotézu o nezávislosti genu a stavu pacienta. Simultánní četnosti znázorněte graficky.

• **Původní datový soubor**  
(co řádek, to subjekt)

• V menu **Statistics** zvolíme  
**Basic statistics**,  
Vybereme **Tables and banners**  
(v češtině **Kontingenční tabulky**)


The screenshot shows the Statistica software interface. The top menu bar includes Home, Edit, View, Insert, Format, Statistics, Data Mining, and Graph. A blue arrow labeled '1' points to the 'Data Mining' tab. The main window displays a data table titled 'Data: 07 priklad\_z\_prednasky\_K...' with columns 'Gen' and 'Stav\_p...'. Below the table is a 'Basic Statistics and Tables' dialog box. A blue arrow labeled '2' points to the 'Tables and banners' option in the 'Quick' tab of the dialog. The dialog also contains other options like Descriptive statistics, Correlation matrices, t-test, etc., and buttons for OK, Cancel, and Options.

	C:\Users\malus...
1	2
Gen	Stav_p...
1	přítomer úmrtí
2	přítomer úmrtí
3	přítomer úmrtí
4	přítomer úmrtí
5	přítomer úmrtí
6	přítomer úmrtí
7	přítomer úmrtí
8	přítomer úmrtí
9	přítomer úmrtí
10	přítomer úmrtí
11	přítomer úmrtí
12	přítomer úmrtí

# Způsob 1: Řešení v softwaru Statistica II




- Vybereme proměnné, které chceme testovat



# Způsob 1: Řešení v softwaru Statistica III




- Na záložce **Options** zaškrtneme **Expected frequencies** (*Očekávané četnosti*)  
(k ověření podmínek dobré aproximace)



- Zaškrtneme Pearsonův chí-kvadrát
- Pokud chceme vypočítat i Cramérův koeficient zaškrtneme Phi & Cramer's V

- Poté se vrátíme na záložku **Advanced**, kde a zvolíme **Detailed two-way tables**



# Způsob 1: Řešení v softwaru Statistica IV

Tab.1: Pozorované četnosti

Summary Frequency Table (07 priklad_z_prednasky_K)			
Marked cells have counts > 10			
(Marginal summaries are not marked)			
Gen	Stav_pacienta úmrtí	Stav_pacienta žijící	Row Totals
přítomen	20	82	102
nepřítomen	10	54	64
All Grps	30	136	166

Tab. 2: Očekávané četnosti

Summary Table: Expected Frequencies (07 priklad_z_pre)			
Marked cells have counts > 10			
Pearson Chi-square: ,421322, df=1, p=,516278			
Gen	Stav_pacienta úmrtí	Stav_pacienta žijící	Row Totals
přítomen	18,43373	83,5663	102,0000
nepřítomen	11,56627	52,4337	64,0000
All Grps	30,00000	136,0000	166,0000



Jsou splněny podmínky dobré approximace?

Tab. 3: Pearsonův chí-kvadrát

Hodnota testové statistiky

Počet stupňů volnosti

p- hodnota

Statistics: Gen(2) x Stav_pacienta(2)		
Statistic	Chi-square	df
Pearson Chi-square	,4213223	df=1
M-L Chi-square	,4277117	df=1
Phi for 2 x 2 tables	,0503794	
Tetrachoric correlation	,0949754	
Contingency coefficient	,0503156	

# Způsob 2: Řešení v softwaru Statistica I



- Na hladině významnosti 0,05 testujte hypotézu o nezávislosti genu a stavu pacienta. Simultánní četnosti znázorněte graficky.

## • Agregovaný datový soubor

- V menu **Statistics** zvolíme **Basic statistics**, vybereme **Tables and banners** (v češtině **Kontingenční tabulky**)

The screenshot shows a Microsoft Excel spreadsheet titled "Basic Statistics and Tables: Spreadsheet11" containing a 4x3 contingency table. The columns are labeled "1 Gen", "2 Stav\_pacienta", and "3 Četnost". The rows represent combinations of "Gen" (přítomen/nepřítomen) and "Stav\_pacienta" (úmrtí/žijící). The data is as follows:


	1 Gen	2 Stav_pacienta	3 Četnost
1	přítomen	úmrtí	20
2	přítomen	žijící	82
3	nepřítomen	úmrtí	10
4	nepřítomen	žijící	54

To the right of the spreadsheet is the "Basic Statistics and Tables" dialog box. In the "Quick" tab, the "Tables and banners" option is selected. Other options include Descriptive statistics, Correlation matrices, t-test, independent, by groups, t-test, independent, by variables, t-test, dependent samples, t-test, single sample, Breakdown & one-way ANOVA, Breakdown; non-factorial tables, Frequency tables, and Probability calculator. Buttons for OK, Cancel, and Options are also visible.

# Způsob 2: Řešení v softwaru Statistica II



- Vybereme proměnné, které chceme testovat



# Způsob 2: Řešení v softwaru Statistica III



- Zapneme **váhy** (vpravo ikonka černých vah **w**), jako váhy vybereme proměnnou **četnost** (tj. proměnnou, ve které jsou uvedeny počty případů jednotlivých kombinací kategorií)

The screenshot shows two dialog boxes over a spreadsheet. The spreadsheet has columns labeled 1 Gen, 2 Stav\_pacienta, and 3 Četnost. The data is as follows:

	1 Gen	2 Stav_pacienta	3 Četnost
1	přítomen	úmrtí	20
2	přítomen	žijící	82
3	nepřítomen	úmrtí	10
4	nepřítomen	žijící	54

The **Crosstabulation Tables: Spreadsheet11** dialog box (highlighted with arrow 1) contains the following settings:

- Specify tables (select variables)
- Review or delete tables
- Number of tables: 1
- Identification of levels in table factors:
  - Use all integer codes in the selected tables
  - Use selected grouping codes only
- Codes: Not selected
- Weighted moments

The **Analysis/Graph Case Weights** dialog box (highlighted with arrow 2) contains the following settings:


- Use Spreadsheet weights (selected)
- Use weights for this Analysis/Graph only
- Weight variable: Četnost
- Status:
  - On
  - Off
- Double-click on edit field to choose from list of all variables. Values of selected variable will be used as case multipliers unless otherwise noted in the respective analysis or analysis module.

Arrow 3 points to the OK button at the bottom right of the **Analysis/Graph Case Weights** dialog box.


# Způsob 2: Řešení v softwaru Statistica IV



- Na záložce **Options** zaškrtneme **Expected frequencies** (*Očekávané četnosti*)  
(k ověření podmínek dobré aproximace)



- Zaškrtneme Pearsonův chí-kvadrát
- Pokud chceme vypočítat i Cramérův koeficient zaškrtneme Phi & Cramer's V



- Poté se vrátíme na záložku **Advanced**, kde a zvolíme **Detailed two-way tables**

# Testování homogeneity (shody struktury)



- Motivace: Zajímá nás výskyt nominálního znaku u  $r$  nezávislých výběrů z  $r$  různých populací.
- Příklad: Je zájem o sport stejný u děvčat jako u chlapců?
- Nulová hypotéza: pravděpodobnostní rozdělení kategoriální proměnné je stejné v různých populacích
- Test: Pearsonův chí-kvadrát

		Dívky      Chlapci		
Zájem o sport	Ano	$a$	$b$	$a+b$
	Ne	$c$	$d$	$c+d$
		$a+c$	$b+d$	$n$

*Některé marginální četnosti (bud' sloupcové, nebo řádkové)  
jsou předem pevně stanoveny*

# Fisherův exaktní test



- Využití ve čtyřpolní tabulce s nízkými četnostmi, které znemožňují použití Pearsonova chí-kvadrát testu.
- Patří mezi **neparametrické testy** pracující s daty na nominální škále, v nejjednodušší podobě ve dvou třídách: pozitivní/negativní, úspěch/neúspěch apod.
- Nulová hypotéza předpokládá rovnoměrné zastoupení sledovaného znaku u dvou nezávislých souborů.
- Slovo exaktní (přímý) znamená, že se přímo vypočítává pravděpodobnost odmítnutí, resp. platnosti nulové hypotézy.

# Fisherův exaktní test



- Výpočet „přesné“ p-hodnoty, která zde hraje roli testové statistiky:
  - spočítá se parciální pravděpodobnost čtyřpolní tabulky  $p_1$ :

Sledovaný jev	Skupina		Celkem
	Experimentální	Kontrolní	
Ano	$a$	$b$	$a + b$
Ne	$c$	$d$	$c + d$
Celkem	$a + c$	$b + d$	$n$

$$p_1 = \frac{(a+b)! * (c+d)! * (a+c)! * (b+d)!}{N! * a! * b! * c! * d!}$$

- Spočítá se  $p_a$  všech možných tabulek při zachování marginálních četností (řádkové a sloupcové součty) a výsledná p-hodnota je součtem  $p_a$  menších nebo stejných jako  $p_1$ , která přísluší pozorované tabulce.

# Fisherův exaktní test – podrobněji



- Založen na výpočtu „přesné“ p-hodnoty (pravděpodobnosti, s jakou bychom dostali stejný nebo ještě extrémnější výsledek při zachování součtu řádků i sloupců v tabulce).
- **Příklad:** Chceme ověřit vztah dvou typů nežádoucích účinků, které jsou summarizovány následující tabulkou:
- **Postup:** Všechny varianty tabulky při zachování součtu řádků a sloupců:

		NÚ II	
		ano	ne
NÚ I	ano	2	3
	ne	6	4

<table border="1"><tr><td>0</td><td>5</td></tr><tr><td>8</td><td>2</td></tr></table>	0	5	8	2	<table border="1"><tr><td>1</td><td>4</td></tr><tr><td>7</td><td>3</td></tr></table>	1	4	7	3	<table border="1"><tr><td>2</td><td>3</td></tr><tr><td>6</td><td>4</td></tr></table>	2	3	6	4	<table border="1"><tr><td>3</td><td>2</td></tr><tr><td>5</td><td>5</td></tr></table>	3	2	5	5	<table border="1"><tr><td>4</td><td>1</td></tr><tr><td>4</td><td>6</td></tr></table>	4	1	4	6	<table border="1"><tr><td>5</td><td>0</td></tr><tr><td>3</td><td>7</td></tr></table>	5	0	3	7
0	5																												
8	2																												
1	4																												
7	3																												
2	3																												
6	4																												
3	2																												
5	5																												
4	1																												
4	6																												
5	0																												
3	7																												

Pravděpodobnosti výskytu jednotlivých tabulek:

0,007

0,093

0,326

0,392


0,163

0,019

Oboustranná p-hodnota (sečtení pravděpodobností stejných nebo menších než je pravděpodobnost pozorované varianty):

$$p = 0,326 + 0,093 + 0,007 + 0,163 + 0,019 = 0,608$$

# Řešení v softwaru Statistica: Fisherův exaktní test



- Na záložce **Options** zaškrtneme **Fisher exact**

- Výstupní tabulka

Statistic	Statistics: Gen(2) x Stav_paci		
	Chi-square	df	p
Pearson Chi-square	.4213223	df=1	p=,51628
M-L Chi-square	,4277117	df=1	p=,51311
Yates Chi-square	,1952605	df=1	p=,65857
Fisher exact, one-tailed			p=,33259
two-tailed			p=,54314
McNemar Chi-square (A/D)	14,71622	df=1	p=,00012
(B/C)	54,79348	df=1	p=,00000

Pro jednostranný test

Pro oboustranný test



# Fisherův exaktní test na webu



- 2 x 2 tabulky: <http://graphpad.com/quickcalcs/contingency1/>
- 2 x 3 tabulky: <http://www.vassarstats.net/fisher2x3.html>
- 2 x 5 (nebo menší) tabulky:  
<http://www.quantatativeskills.com/sisa/statistics/fiveby2.htm>
- 3 x 3 tabulky: <http://vassarstats.net/fisher3x3.html>

# Test hypotézy o symetrii (McNemarův test pro čtyřpolní tabulku)



- Motivace: Na osobách sledujeme binární proměnnou před pokusem a po něm, cílem je zjistit, zda došlo ke změně v rozdělení této proměnné.
- Analýza párových dichotomických proměnných**

Četnostní tabulka

		po		$n_j.$
		+	-	
před	+	$a$	$b$	$a+b$
	-	$c$	$d$	$c+d$
		$a+c$	$b+d$	$n$

Tabulka teoretických pravděpodobností

		po		$p_{1.}$
		+	-	
před	+	$p_{11}$	$p_{12}$	$p_{1.}$
	-	$p_{21}$	$p_{22}$	
		$p_{.1}$	$p_{.2}$	

- Nulová hypotéza:  $p_{ij} = p_{ji}$ , pokus nemá vliv na výskyt daného znaku
- Testová statistika:  $\chi^2 = \frac{(|b-c|-1)^2}{b+c}$  pokud je větší než kritická hodnota  $\chi^2$  rozdělení o jednom stupni volnosti (vhodné pro počty údajů  $b+c > 8$ ), pak nulovou hypotézu zamítáme

# McNemarův test: příklad I



Zjistěte, zda úspěch našich sportovců na olympiádě vede ke změně postojů žáků ke sportování.


**Nulová hypotéza:** Počet žáků, kteří změní svůj postoj pozitivním směrem, je pouze náhodně odlišný od počtu žáků, kteří změní svůj postoj negativním směrem.

		Postoj po olympiádě		
		+	-	
Postoj před olympiádou	+	5	3	8
	-	16	2	18
		21	5	26

$$\chi^2 = \frac{(|3-16|-1)^2}{3+16} = 7,58$$

Stupně volnosti

Tabulky:  $\chi^2_{1-\alpha} (v = k(k-1)/2 = 1) = 3,84$



**H<sub>0</sub> zamítnuta**

Závěr: Úspěch našich sportovců má pozitivní vliv na postoj žáků vzhledem k provozování sportu.

# Řešení v softwaru Statistica: McNemarův test

Datový soubor

	1 postoj_pred_vyukou	2 postoj_po_vyuce	3 cetnost
1	kladný	kladný	5
2	záporný	kladný	16
3	kladný	záporný	3
4	záporný	záporný	2

Výstupní kontingenční tabulka

postoj_pred_vyukou	2-rozměrná tabulka: Pozorované četnosti (prikad_pos Četnost označených buněk > 10)		
	postoj_po_vyuce kladný	postoj_po_vyuce záporný	Rádk. součty
kladný	5	3	8
záporný	16	2	10
Celk.	21	5	26

Crosstabulation Tables Results: 07 priklad\_z\_prednasky\_Kontingencki

Quick | Advanced | Options

Compute tables

Highlight counts > 10

Expected frequencies

Residual frequencies

Percentages of total count

Percentages of row counts

Percentages of column counts

Statistics for two-way tables

Pearson & M-L Chi-square

Fisher exact, Yates, McNemar (2 x 2) highlighted

Phi (2x2 tables) & Cramér's V & C

Kendall's tau-b & tau-c

Gamma

Spearman rank order correlation

Sommer's d

Uncertainty coefficients

Summary

Cancel

Options ▾

By Group...

To compute Max. Likelihood Chi-squares and to analyze multi-way frequency tables use the Log-Linear module.

- Na záložce **Options** zaškrtneme **McNemar (2x2)**

- Výstupní tabulka

Statist.	Chí-kvadr.	sv	p
<b>Yatesův chí-kv.</b>	1.074735	df=1	p=.29988
Fisherův přesný, 1-str.			p=.15026
Fisherův přesný, 2-str.			p=.28051
<b>McNemarův chí-kv. (A/D)</b>	.5714286	df=1	p=.44969
<b>McNemarův chí-kv. (B/C)</b>	7.578948	df=1	p=.00591

2 hodnoty testových statistik a p-hodnoty, podle toho, kde jsou ve výstupní kontingenční tabulce uloženy četnosti, u kterých jsme při opakovém měření zaznamenali rozdílné výsledky (A/D nebo B/C)

# Společný příklad – testování homogenity




Očkování proti chřipce se zúčastnilo 460 dospělých, z nichž 240 dostalo očkovací látku proti chřipce a 220 dostalo placebo. Na konci experimentu onemocnělo 100 lidí chřipkou, 20 z nich bylo z očkované skupiny a 80 z kontrolní skupiny. Je to dostatečný důkaz, že očkovací látka byla účinná?

**Nulová hypotéza:** Procento výskytu chřipky je v očkované a kontrolní skupině stejné.

1. Vytvořte si na základě zadání datový soubor v softwaru *STATISTICA* (agregovaná data ve formě kontingenční tabulky).
2. Testujte platnost nulové hypotézy pomocí Pearsonova chí-kvadrát testu.
3. Testujte platnost nulové hypotézy pomocí Fisherova exaktního testu.
4. Který z testů je vhodné použít a proč?

# Základní rozhodování o výběru statistických testů - jednovýběrový binomický test



# Jednovýběrový binomický test



- test pro podíl u jednoho výběru
- **Liší se podíl ( $p$ ) pacientů s výskytem sledovaného jevu od předpokládané (referenční) hodnoty ( $\pi$ )?**
- např. liší se procento pacientů s nežádoucími účinky léčby od předpokládaného procenta?
- výpočet: [https://www.medcalc.org/calc/test\\_one\\_proportion.php](https://www.medcalc.org/calc/test_one_proportion.php)

# Jednovýběrový binomický test – příklad



- **Příklad:** Z 50 studentů, kteří si zvolilo maturitu z matematiky, ji v letošním roce neudělalo 12. Ověřte, zda podíl neúspěšných studentů je stejný jako v předchozím roce, kdy byla neúspěšnost 5%. [Test for one proportion calculator](#)

- Tzn. hypotézy budou mít tvar:

$$H_0 : p = \pi \quad \text{a} \quad H_1 : p \neq \pi$$

- **Řešení:**

- $\pi = 5\%$
- $p = 12/50 = 0,24 \Rightarrow 24\%$

- **Závěr:**

Podíl neúspěšných studentů  
je statisticky významně odlišný od  
podílu v předchozím roce.

Observed proportion

Observed proportion (%):

Sample size:

Null hypothesis value

Null hypothesis value (%):

**Test**

Results

z-statistic	6.164
Significance level	$P < 0.0001$
95% CI of observed proportion	13.06 to 38.17

# Základy korelační analýzy



Korelace a regrese  
Pearsonův korelační koeficient  
Spearmanův korelační koeficient

# Proč hodnotit vztah dvou spojitéch veličin?




- Vztah mezi dvěma spojitymi veličinami v jedné skupině:
  1. Chceme zjistit, jestli mezi nimi **existuje vztah** – např. jestli vyšší hodnoty jedné veličiny znamenají nižší hodnoty jiné veličiny;
  2. Chceme **predikovat hodnoty** jedné veličiny na základě znalosti hodnot jiných veličin;
  3. Chceme **kvantifikovat vztah** mezi dvěma spojitymi veličinami – např. pro použití jedné veličiny namísto druhé veličiny.

# Korelační a regresní analýza



- **Korelační analýza** je využívána pro vyhodnocení míry vztahu dvou spojitých proměnných. Obdobně jako jiné statistické metody, i korelace mohou být parametrické nebo neparametrické.
- **Regresní analýza** vytváří model vztahu dvou nebo více proměnných, tedy jakým způsobem jedna proměnná (vysvětlovaná) závisí na jiných proměnných (prediktorech). Regresní analýza je obdobně jako ANOVA nástrojem pro vysvětlení variability hodnocené proměnné.


# Základní rozhodování o výběru statistických testů - korelační analýza



MU

# Vizuální hodnocení vztahu dvou proměnných

- Nejjednodušší formou je **bodový graf** (x-y graf), tzv. scatterplot.
- Vztah výšky a váhy studentů  
Biostatistiky pro matematické biologie – jaro 2010:







# Korelační koeficienty



- **Korelační koeficient ( $r$ )** – kvantifikuje míru vztahu mezi dvěma spojitémi veličinami ( $X$  a  $Y$ ).
  - **Pearsonův korelační koeficient** – parametrický, hodnotí míru **lineární** závislosti mezi 2 spojitémi proměnnými,
  - **Spearmanův korelační koeficient** – neparametrický, hodnotí míru **lineární** pořadové závislosti mezi 2 spojitémi proměnnými.
  - Hodnota  $r$  je kladná, když vyšší hodnoty  $X$  souvisí s vyššími hodnotami  $Y$ , naopak hodnota  $r$  je záporná, když nižší hodnoty  $X$  souvisí s vyššími hodnotami  $Y$ .
  - Nabývá hodnot od -1 do 1:
    - $r = 0 \rightarrow$  nekorelované
    - $r > 0 \rightarrow$  kladně korelované
    - $r < 0 \rightarrow$  záporně korelované

# Korelační koeficienty - ukázky



# Test hypotézy $H_0: r = 0$


---




- K měření těsnosti lineárního vztahu 2 spojitého proměnných  
 $r = 0 \rightarrow \text{nekorelované}$   
 $r > 0 \rightarrow \text{kladně korelované}$   
 $r < 0 \rightarrow \text{záporně korelované}$
- $H_0$ : proměnné X, Y jsou nezávislé náhodné veličiny  
 $(r = 0)$   
 $H_A$ : proměnné X, Y nejsou nezávislé náhodné veličiny  $(r \neq 0)$
- Testování pomocí intervalu spolehlivosti nebo výpočet testové statistiky (srovnání s kritickou hodnotou nebo výpočet p-hodnoty)

# Problémy s výpočtem $r$



## Problém více skupin



## Nelineární vztah



## Problém velikosti výběru




# Problémy s výpočtem Pearsonova kor. koef. I




## Odlehlá hodnota

Může způsobit, že korelace vyjde významně, i když ve skutečnosti tam žádný vztah není!



Může způsobit, že korelace bude méně významná (či dokonce nevýznamná), i když ve skutečnosti tam vztah je!






Pearsonův korelační koeficient:  
 $r = 0,65$  ( $p = 0,029$ )  
Spearmanův korelační koeficient:  
 $r_s = 0,95$  ( $p < 0,001$ )

# Problémy s výpočtem Pearsonova kor. koef. II



- Při srovnání dvou spojitéch proměnných je nutné vykreslovat bodový graf, protože histogramy pro jednotlivé proměnné zvlášť nám nemusejí odhalit odlehlé hodnoty!



# Řešení v softwaru Statistica: Pearsonův korelační koeficient I


Prozkoumejte lineární vztah mezi výškou a váhou u 13 studentů. Testujte hypotézu, že jsou tyto proměnné nezávislé.

1. Záložka **Statistics**

2. **Basic Statistics**

3. **Correlation matrices**

4. Potvrďme: **OK**



# Řešení v softwaru Statistica: Pearsonův korelační koeficient II


5. Vybereme spojité proměnné pro hodnocení vztahu (váha a výška) ve **One variable list**.

Na záložce **Options** můžeme vybrat formu výstupu (pouze p-hodnoty, matice korelačních koeficientů a p-hodnot ap.).

## 6. Summary: Correlations

Jedna z možných výstupních tabulek:

Variable	Correlations (priklad_vyska_vaha.sta)			
	Means	Std.Dev.	vyska	vaha
vyska	173,3846	5,31568	1,000000	0,639675
vaha	65,8462	12,54224	0,639675	1,000000





p-hodnota < 0,05 - test hypotézy  $H_0: r = 0$ ,  
lze vypsat i konkrétní hodnotu (změna formy výstupu na záložce **Options** – skutečnou p-hodnotu zjistíme zatrhnutím **Display r, p-values, and N's**)  
→ Pearsonovy korelační koeficienty

# Řešení v softwaru Statistica: Pearsonův korelační koeficient III

Záložka **Quick / Advanced** umožňuje vykreslit různé druhy grafů (2D, 3D v případě více proměnných, matice bodových grafů s histogramy na diagonále ap.).

*Jsou v daném případě splněny předpoklady (dvourozměrné normální rozdělení, absence odlehлých pozorování, lineární vztah)?*



Na záložce **Color maps** můžeme získat matici korelačních koeficientů (nebo příslušných p-hodnot) obarvenou dle odpovídající barevné škály. Vhodné zejména při zkoumání vztahů mezi více spojitými proměnnými.

# Řešení v softwaru Statistica: Spearmanův korelační koeficient I

Prozkoumejte pořadový vztah mezi výškou a váhou u 13 studentů. Testujte hypotézu, že jsou tyto proměnné nezávislé.

1. Záložka **Statistics**
2. **Nonparametrics**
3. **Correlations**
4. Potvrďme: **OK**

The screenshot shows the Statistica software interface. The menu bar at the top includes File, Home, Edit, View, Format, Statistics (which is highlighted), Data Mining, Graphs, Tools, and Data. Below the menu is a toolbar with icons for Basic Statistics, Multiple Regression, ANOVA, Nonparametrics (highlighted), Distribution Fitting, More Distributions, Advanced Models, Neural Nets, Mult/Exploratory, PLS, PCA, Power Analysis, Variance, and Advanced/Multivariate. A data grid on the left contains 13 rows of data with columns labeled '1' (student ID), '2' (height), and '3' (weight). To the right of the data grid is a 'Nonparametric Statistics' dialog box. The 'Quick' tab is selected, showing various nonparametric tests. The 'Correlations (Spearman, Kendall tau, gamma)' option is highlighted with a blue arrow labeled '3'. At the bottom right of the dialog box is an 'OK' button, which has a blue arrow labeled '4' pointing to it. Other buttons in the dialog include Cancel, Options, Open Data, Select Cases, and a small icon.

	1	2	3
	výška	váha	
1	175	69	
2	166	55	
3	170	67	
4	169	52	
5	188	90	
6	175	53	
7	176	57	
8	171	57	
9	173		
10	175		
11	173	62	
12	174	90	
13	169	63	


# Řešení v softwaru Statistica: Spearmanův korelační koeficient II

5. Výběr proměnných –  
**Variables – Select variables**  
(vyska, vaha) – **OK**

6. Pod možností Compute můžeme vybrat formu výstupu (čtvercová matice - **Square matrix**, příp. detailní výsledky).

7. Lze vykreslit i matici bodových grafů s histogramy na diagonále (**Scatterplot matrix for all variables**).

Jedna z forem výstupní tabulky:



p-hodnota <0,05 - test hypotézy  $H_0: r = 0$ ,  
lze vyspat i konkrétní hodnotu přepnutím **Compute** na **Detailed report**

Spearman Rank Order Correlations (priklad_vyska_vaha.sta)		
Variable	vyska	vaha
vyska	1,000000	0,469452
vaha	0,469452	1,000000

**Spearmanova korelační koeicienty**

# Samostatný úkol



Testování nezávislosti  
Testování homogeneity

# 1. Příklad k procvičení



1. Testujte hypotézu, že **barva vlasů a barva očí spolu nesouvisí**. K dispozici jsou údaje od 6 800 mužů (*Yule, G. U., Kendall, M.G.: An Introduction to the Theory of Statistics, 14th ed. Griffin, London, 1950*).
2. Vypočítejte Cramérův koeficient a interpretujte jej.

	Světlá	Kaštanová	Černá	Zrzavá	Celkem
Modrá	1768	807	189	47	2811
Šedá nebo zelená	946	1387	746	53	3132
Tmavohnědá	115	438	288	16	857
Celkem	2829	2632	1223	116	6800

***Nezapomeňte ověřit podmínky dobré approximace!***

## 2. Příklad k procvičení



- Ve Skotsku byla provedena studie, která měla prokázat, **zda procentuální zastoupení krevních skupin na celém území je homogenní nebo není**. V oblasti Eskdale bylo náhodně vybráno 100 osob, v Annadale 125 osob a v Nithsdale 253 osob (*Osborn J. F., 1979, Statistical Exercises in Medical Research, Blackwell Scientific publications, Oxford*)

	A	B	O	AB	Celkem
Eskade	33	6	56	5	100
Annandale	54	14	52	5	125
Nithsdale	98	35	115	5	253
Celkem	185	55	223	15	478

***Nezapomeňte ověřit podmínky dobré approximace!***

# Výsledky k samostatnému úkolu



Testování nezávislosti  
Testování homogenity

# 1. Příklad k procvičení



1. Testujte hypotézu, že **barva vlasů a barva očí spolu nesouvisí**. K dispozici jsou údaje od 6 800 mužů (Yule, G. U., Kendall, M.G.: *An Introduction to the Theory of Statistics*, 14th ed. Griffin, London, 1950).
2. Vypočítejte Cramérův koeficient a interpretujte jej.

Výsledky:

$\chi^2$ -kvadrát = 1073,51

$p < 0,001$  ... na hladině významnosti zamítáme nulovou hypotézu o nezávislosti barvy očí a barvy vlasů (**před provedením testu jsme zkontovali podmínky dobré approximace**),

Cramérův koeficient = 0,28 ... mezi barvou očí a barvou vlasů je slabá závislost.

## 2. Příklad k procvičení



1. Ve Skotsku byla provedena studie, která měla prokázat, **zda procentuální zastoupení krevních skupin na celém území je homogenní nebo není**. V oblasti Eskdale bylo náhodně vybráno 100 osob, v Annadale 125 osob a v Nithsdale 253 osob (*Osborn J. F., 1979, Statistical Exercises in Medical Research, Blackwell Scientific publications, Oxford*)

**Výsledky:**

**chi-kvadrát = 10,454**

**P = 0,107 ... nelze zamítnout nulovou hypotézu, že procentuální zastoupení krevních skupin na celém území je homogenní / stejné  
(před provedením testu jsme zkontrolovali podmínky dobré approximace).**