

# Párový neparametrický test

- Wilcoxonův test: obdobně seřadíme difference a testujeme proti kritické hodnotě daného testu
- Výpočet pomocí STATISTICY

# Dieta laboratorních krys

- Máme dva typy diety. Zkontrolujte předpoklad párovosti a vhodnosti použití parametrického testu ( $r=0,98$ )
- můžeme použít oba testy – nicméně, zde použijeme nepárovou variantu testu.

[korelace ✓, Normalita diferencí ✓  
(nicméně 0.094 je vcelku málo, šly by použít oba testy),  
parametrický:  $p=0.102 \Rightarrow$  nezamítáme  $H_0$   
Neparametricky: Wilcoxon :  $p=0.056 \Rightarrow$  nezamítáme  $H_0$   
Znaménkový test:  $p=0.080 \Rightarrow$  nezamítáme  $H_0$ ]



# Obdoba – jednovýběrový neparametrický test

- Wilcoxonův znaménkový test
- ve STATISTICE není naimplementovaný
- nicméně porovnááme hodnotu mediánu jednoho výběru proti nějaké hodnotě
- můžeme využít Wilcoxonův test pro párové uspořádání testu tak, že druhý výběr bude sestávat pouze z hodnoty, s kterou chceme porovnávat náš původní výběr

# Vrtačka

- *Vrtacka.sta*
- Testujte na hladině významnosti 0,05 , že výdrž jednoho vrtáku ve vrtačce je 500 otáček




# Kontingenční tabulky

# Typy dat - opakování

- **Kvalitativní (kategoriální) data:**

- Binární data



- Nominální data



- Ordinální data



- **Kvantitativní data:**

- Intervalová data



- Poměrová data



# Kontingenční tabulka

- Frekvenční sumarizace dvou 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.

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

# Kontingenční tabulky – hypotézy

- **Nezávislost** (Pearsonův chí-kvadrát test)
  - Jeden výběr, dvě charakteristiky – obdoba nepárového uspořádání
  - Příklad: pacienti s AD – pohlaví × vzdělání (VŠ, SŠ, ZŠ)
- **Shoda struktury** (Pearsonův chí-kvadrát test)
  - Více výběrů, jedna charakteristika – obdoba nepárového uspořádání
  - Příklad: pacienti s AD v několika nemocnicích × věková struktura
- **Symetrie** (McNemarův test)
  - Jeden výběr, opakovaně jedna charakteristika – obdoba párového uspořádání
  - Příklad: Znamky z testu A a z testu B (Jsou testy stejně obtížné?)



# Pearsonův chí-kvadrát test

- Založen na myšlence srovnání pozorovaných a očekávaných četností kategorií dvou proměnných.
- Pozorované četnosti jednotlivých kategorií první proměnné a druhé proměnné nám vyjadřují  $n_{ij}$ .
- Očekávané četnosti jednotlivých kategorií lze vypočítat pomocí:

$$e_{ij} = \frac{n_{i.} \cdot n_{.j}}{n}$$

**POZOROVANÉ ČETNOSTI**

X \ Y	1	2	$\Sigma$
1	$n_{11}$	$n_{12}$	$n_{1.}$
2	$n_{21}$	$n_{22}$	$n_{2.}$
$\Sigma$	$n_{.1}$	$n_{.2}$	$n$

**OČEKÁVANÉ ČETNOSTI**

X \ Y	1	2	$\Sigma$
1	$e_{11}$	$e_{12}$	$e_{1.}$
2	$e_{21}$	$e_{22}$	$e_{2.}$
$\Sigma$	$e_{.1}$	$e_{.2}$	$e$

# Pearsonův chí-kvadrát test

- Výpočet testové statistiky:

$$X^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(n_{ij} - e_{ij})^2}{e_{ij}}$$

- Nulovou hypotézu o nezávislosti dvou kategoriálních proměnných zamítáme na hladině významnosti  $\alpha$ , když

$$X^2 \geq \chi_{(1-\alpha)}^2 (r - 1)(c - 1)$$

- $r$  – počet řádků  
 $c$  – počet sloupců

# Předpoklady Pearsonova chí-kvadrát testu

- Nezávislost jednotlivých pozorování
- Alespoň 80 % buněk musí mít očekávanou četnost ( $e_{ij}$ ) větší než 5
- 100 % buněk musí mít očekávanou četnost ( $e_{ij}$ ) větší než 2
- Může nám pomoci slučování kategorií, ale můžeme slučovat jen slučitelné kategorie!



# Příklad I. nezávislost

- Máme 74 pacientů s krevní skupinou A0. Naším cílem je zjistit, zda u těchto pacientů je věk nezávislý na přítomnosti sledovaného onemocnění.

**Pozorované četnosti**

A0	<25	25-40	>40	Celkem
nemoc	9	16	6	31
zdravý	13	25	5	43
Celkem	22	41	11	74

**Očekávané četnosti**

A0	<25	25-40	>40	Celkem
nemoc	9,22	17,18	4,61	-
zdravý	12,78	23,82	6,39	-
Celkem	-	-	-	-

$$\chi^2 = \frac{(9-9.22)^2}{9.22} + \frac{(16-17.18)^2}{17.18} + \dots + \frac{(5-6.39)^2}{6.39} \cong 0.87$$

$$\chi^2_{(1-0,05)}(2) \cong 5,99$$

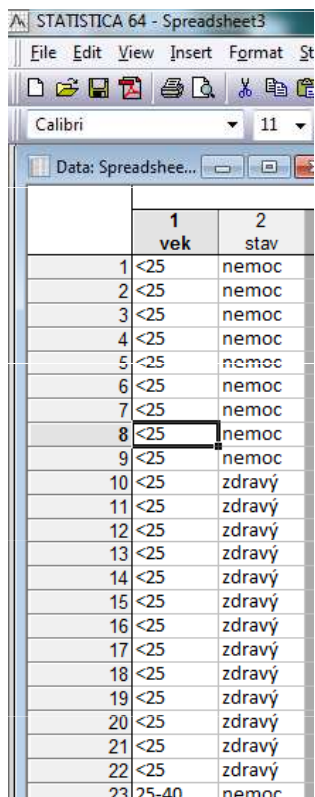


Nezamítáme nulovou hypotézu.

Tedy u těchto pacientů je věk nezávislý na daném onemocnění.

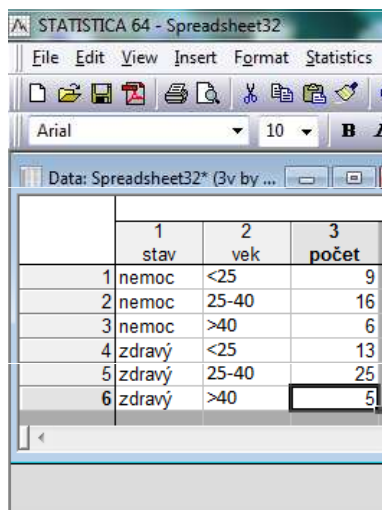
# Řešení STATISTICA

- 2 možné vstupy



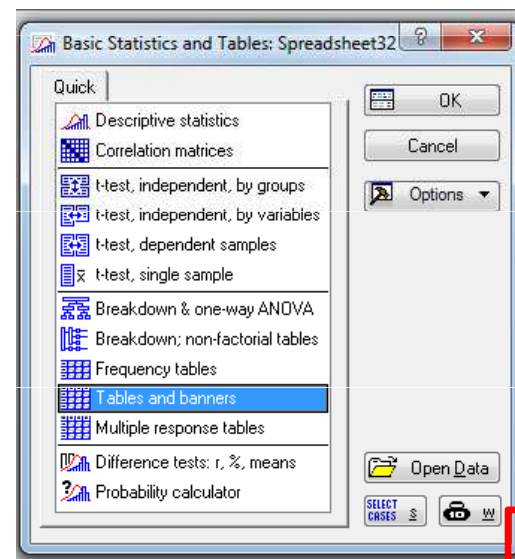
	1 vek	2 stav
1	<25	nemoc
2	<25	nemoc
3	<25	nemoc
4	<25	nemoc
5	<25	nemoc
6	<25	nemoc
7	<25	nemoc
8	<25	nemoc
9	<25	nemoc
10	<25	zdravý
11	<25	zdravý
12	<25	zdravý
13	<25	zdravý
14	<25	zdravý
15	<25	zdravý
16	<25	zdravý
17	<25	zdravý
18	<25	zdravý
19	<25	zdravý
20	<25	zdravý
21	<25	zdravý
22	<25	zdravý
23	25-40	nemoc

každý případ z tabulky odpovídá jednomu řádku

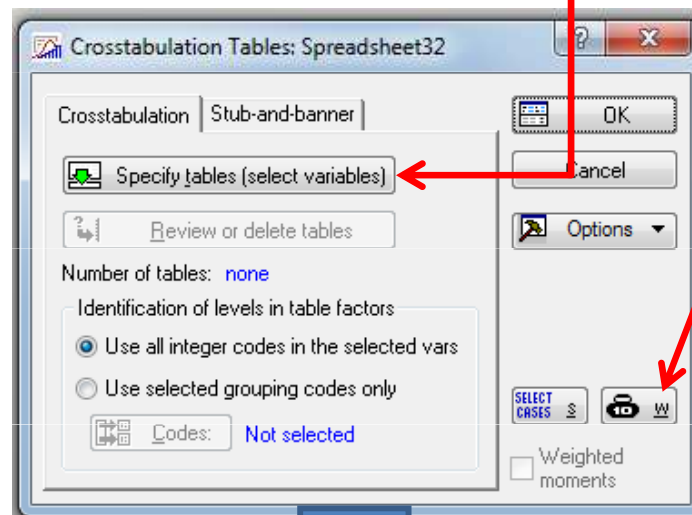


	1 stav	2 vek	3 počet
1	nemoc	<25	9
2	nemoc	25-40	16
3	nemoc	>40	6
4	zdravý	<25	13
5	zdravý	25-40	25
6	zdravý	>40	5

každá kombinace má přiřazený počet výskytů


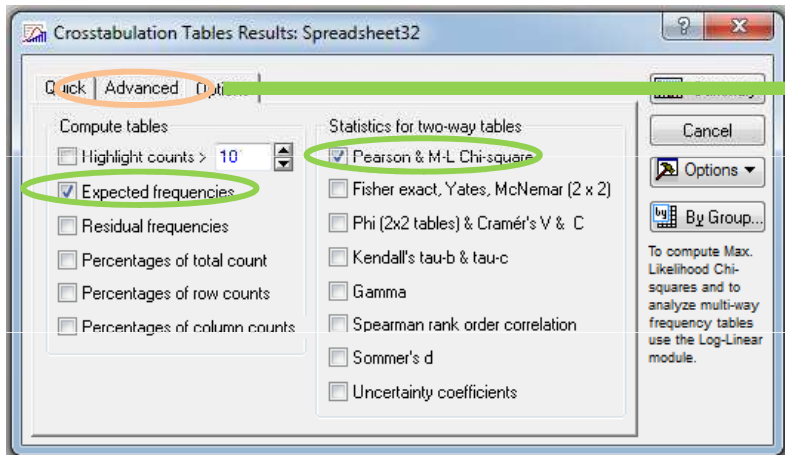


zvolit proměnné (vek a stav)



V případě, že je vstupem tabulka II, pak je třeba jako váhu nastavit počet výskytů dané kombinace kategorií

# Řešení STATISTICA



1.tabulka – pozorované četnosti

2.tabulka – očekávané četnosti

3.tabulka – statistiky

Workbook6\* - 2-Way Summary Table: Observed Frequencies (Spreadsheet32)

stav	vek			Row Totals
	<25	25-40	>40	
nemoc	9	16	6	31
zdravý	13	25	5	43
Totals	22	41	11	74

Workbook6\* - 2-Way Summary Table: Expected Frequencies (Spreadsheet32)

stav	vek			Row Totals
	<25	25-40	>40	
nemoc	9.21622	17.17568	4.60811	31.00000
zdravý	12.78378	23.82432	6.39189	43.00000
Totals	22.00000	41.00000	11.00000	74.00000

Statistics: stav(2) x vek(3) (Sp

Statistic	Chi-square	df	p
<b>Pearson Chi-square</b>	.8707432	df=2	p=.64702
M-L Chi-square	.8595926	df=2	p=.65064
Phi	.1084749		
Contingency coefficient	.1078423		
Cramér's V	.1084749		

**ZKONTROLOVAT PŘEDPOKLADY !!!**

# Příklad II. nezávislost

- Na hladině významnosti 0,05 testujte hypotézu o nezávislosti pedagogické hodnosti a pohlaví

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



[ $X^2 = 3,5$  ;  $p = 0,1739$ ]

# Příklad III.

- Máme data z dotazníku od 100 mužů, kteří odpovídali na to, jaké sporty dělají. Zjistěte, zda se preference pro americký fotbal dají srovnávat s preferencemi baseballu.



[nejsou splněny podmínky dobré aproximace – poslučování (Always + Usually),  
(Sometimes+Never) ->  $\chi^2 = 33,15$  ;  $p < 0.001$ ]






# Příklad I. shoda struktury

- Máme údaje o barvě očí u třech ročníků. Rozhodněte, zda se na hladině významnosti 0,05 liší procentuální zastoupení jednotlivých barev očí v těchto ročnících.

	modre	hnede	zelene
1 ročník	15	25	15
2 ročník	10	18	15
3 ročník	10	26	16

vizualizace procentuální zastoupení:



$$[X^2=1,54 ; p=0,819]$$

# Příklad II. shoda struktury

- Zjistěte, zda se liší intenzita kouření s rozdílným postavením ve firmě...

	Nekuřák	Lehký	Střední	Těžký
Sr. Manager	8	4	6	4
Jr. Manager	8	6	14	8
Sr. Empl	25	10	12	4
Jr. Empl	18	24	33	13
Secretar	10	6	7	2

[ $X^2 = 18,88$  ;  $p = 0,092$ ]



# McNemarův test – test symetrie

- obdoba párového testu – pouze čtyřpolní tabulky
- Testová statistika pro čtyřpolní tabulku:

$$X^2 = \frac{(b - c)^2}{b + c}$$

Veličina X	Veličina Y		Celkem
	Y = 1	Y = 2	
X = 1	a	b	a + b
X = 2	c	d	c + d
Celkem	a + c	b + d	n

- Zaměřuje se pouze na pozorování, u kterých jsme při opakovaném měření zaznamenali rozdílné výsledky – za platnosti  $H_0$  by jejich četnosti (označeny b a c) měly být stejné.
- Testová statistika pro obecnou čtvercovou kontingenční tabulku:

$$X^2 = \sum_{i < j} \frac{(n_{ij} - n_{ji})^2}{n_{ij} + n_{ji}}$$

# Příklad I.

- Liší se tlak před podáním a po podání léku?

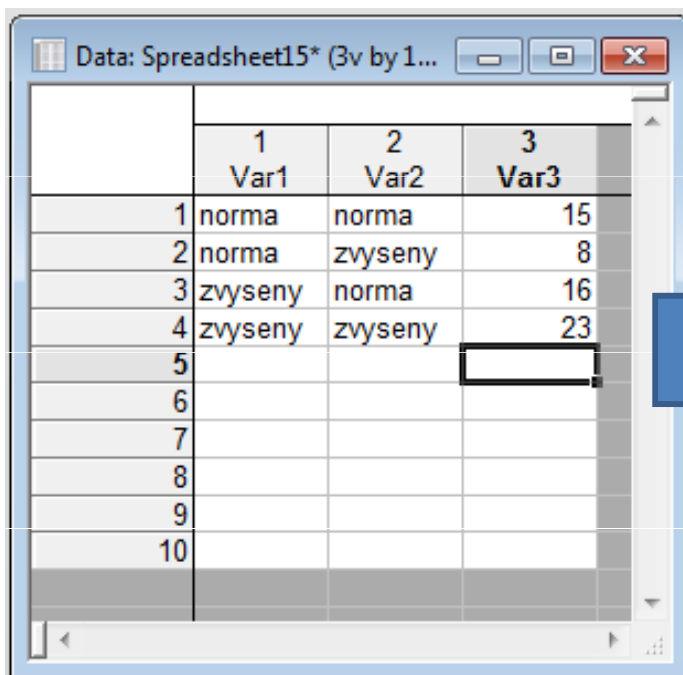
		po	
		v normě	zvýšený
před	v normě	15	8
	zvýšený	16	23

$$X^2 = \frac{(8-16)^2}{8+16} \cong 2,67$$

$$\chi^2_{(1-0,05)}(1) \cong 3,84$$




# Výpočet ve STATISTICE



	1 Var1	2 Var2	3 Var3
1	norma	norma	15
2	norma	zvyseny	8
3	zvyseny	norma	16
4	zvyseny	zvyseny	23
5			
6			
7			
8			
9			
10			

stejně jako obyčejný chí test,  
pouze v možnostech  
zaškneme McNemara



Statistic	Statistics: Var1(2) x Var2(2) (		
	Chi-square	df	p
<b>Pearson Chi-square</b>	3.386845	df=1	p=.06572
M-L Chi-square	3.427852	df=1	p=.06411
Yates Chi-square	2.488294	df=1	p=.11470
Fisher exact, one-tailed			p=.05691
two-tailed			p=.11382
McNemar Chi-square (A/D)	1.289474	df=1	p=.25614
(B/C)	2.041667	df=1	p=.15304

STATISTICA používá korekci pro nespojitost,  
proto trochu jiný výsledek ...

# Příklad II.

- Máme zjistit, zda požití alkoholu ovlivňuje schopnost řidičů projet nějakou trasu.



Před požitím alkoholu	Po požití alkoholu		n <sub>j</sub> .
	bezchybně	s chybami	
bezchybně	45	35	80
s chybami	15	5	20
n <sub>k</sub>	60	40	100

$$[X^2 = 8 ; p \approx 0,005]$$

# Příklad III.

- Zjišťování přítomnosti onemocnění před a po provedení léčby

Disease	After: present	After: absent	Row total
Before: present	101	121	222
Before: absent	59	33	92
Column total	160	154	314



[Chi-square = 20.67,  $p < 0.001$ ]

# Malý počet

- Pokud čtyřpolní tabulka – Fisherův exaktní test
- Jinak pokusit se kategorie smysluplně poslučovat



# Fisherův exaktní test

- Určen pro čtyřpolní tabulky, **je vhodný i pro tabulky s malými četnostmi** – pro ty, které nesplňují předpoklad Pearsonova chí-kvadrát testu.
- 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 sumarizovány následující tabulkou:

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

- **Postup:** Všechny varianty tabulky při zachování součtu řádků a sloupců:

0	5	1	4	2	3	3	2	4	1	5	0
8	2	7	3	6	4	5	5	4	6	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):

$$p = 0,326 + 0,093 + 0,007 + 0,163 + 0,019 = \mathbf{0,608}$$

# Příklad I. – Fisherův exaktní test

- V náhodném výběru 50 obézních dětí byla zjišťována obezita rodičů. X – obezita matky, Y-obezita otce. Na hladině významnosti 0,05 ověřte, zda lze zamítnout hypotézu o nezávislosti veličin X a Y.

X	Y		$n_{j\cdot}$
	ano	ne	
ano	15	9	24
ne	7	19	26
$n_{\cdot k}$	22	28	50



### Výpočet pomocí systému STATISTICA:

Vytvoříme datový soubor o třech proměnných X, Y (varianty 0 – neobézní, 1 – obézní) a četnost a čtyřech případech:

	1 X	2 Y	3 četnost
1	obézní	obézní	15
2	obézní	neobézní	9
3	neobézní	obézní	7
4	neobézní	neobézní	19

Statistiky – Základní statistiky/tabulky – OK – Specif. Tabulky – List 1 X, List 2 Y – OK, zapneme proměnnou vah četnost – OK, Výpočet – na záložce Možnosti zaškrtneme Fisher exakt., Yates, McNemar (2x2). Dostaneme výstupní tabulku:

Statist.	Statist. : X(2) x Y(2) (obezita rodicu)		
	Chí-kvadr.	sv	p
Pearsonův chí-kv.	6,410777	df=1	p=,01134
M-V chí-kvadr.	6,548348	df=1	p=,01050
Yatesův chí-kv.	5,048207	df=1	p=,02465
Fisherův přesný, 1-str.			p=,01188
2-stranný			p=,02163
McNemarův chí-kv. (A/D)	,2647059	df=1	p=,60691
(B/C)	,0625000	df=1	p=,80259

Vidíme, že p-hodnota pro Fisherův exaktní oboustranný test je 0,02163, tedy na hladině významnosti 0,05 zamítáme hypotézu, že obezita matky a otce spolu nesouvisí.