LEKCE 7
ZÁKLADY BIVARIAČNÍ ANALÝZY: ROZLOŽENÍ DAT V KONTINGENČNÍ TABULCE

PROCEDURA CROSSTABS

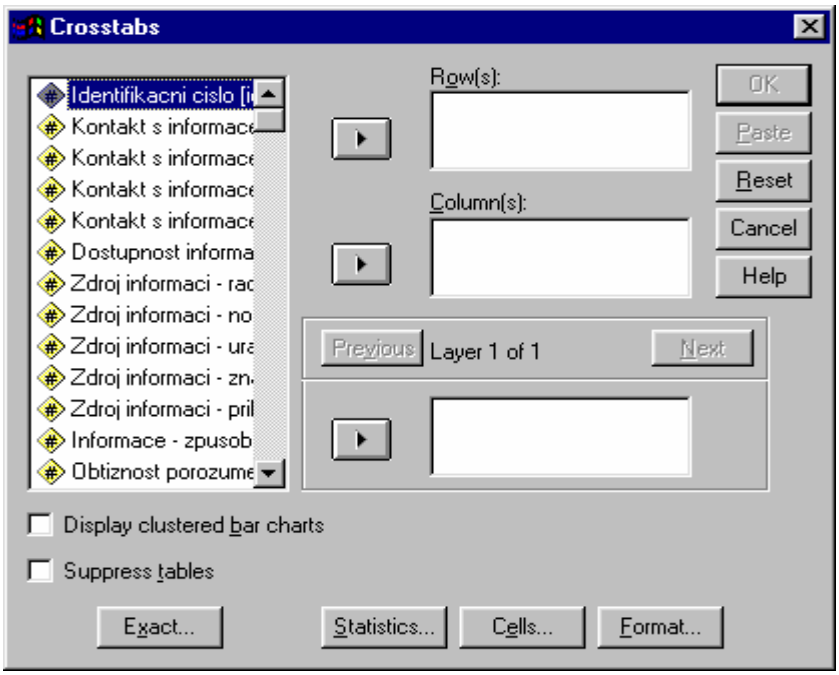

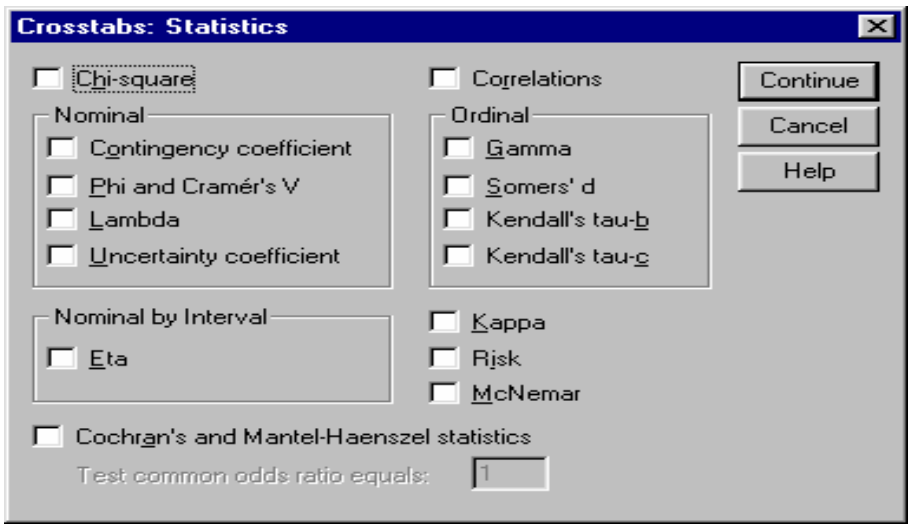

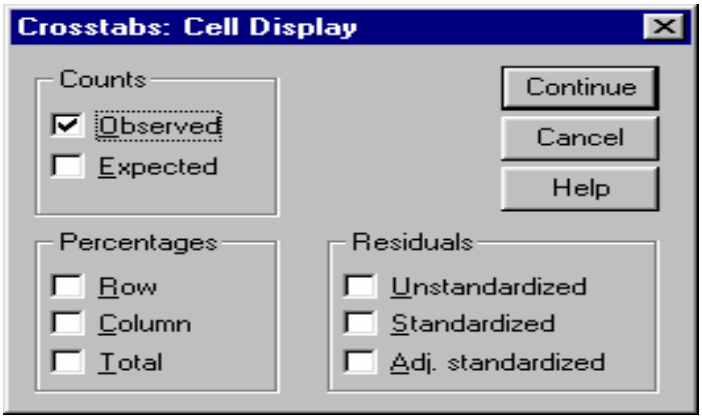

KONTINGENČNÍ TABULKA
(absolutní četnosti)

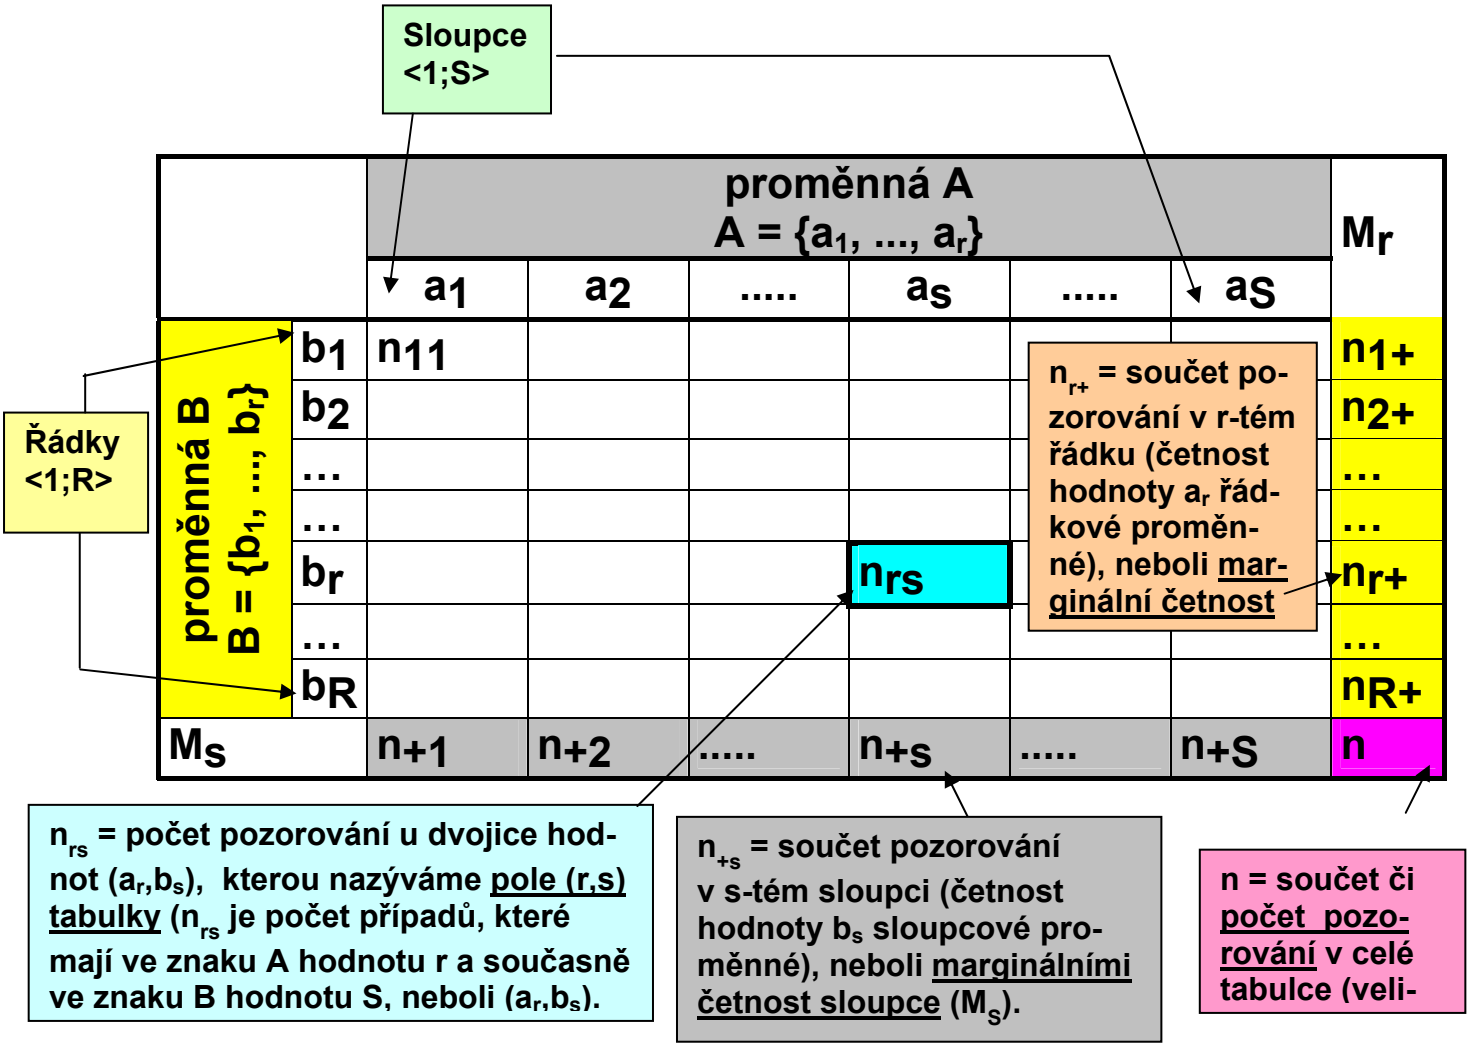

KONTINGENČNÍ TABULKA
(relativní četnosti)

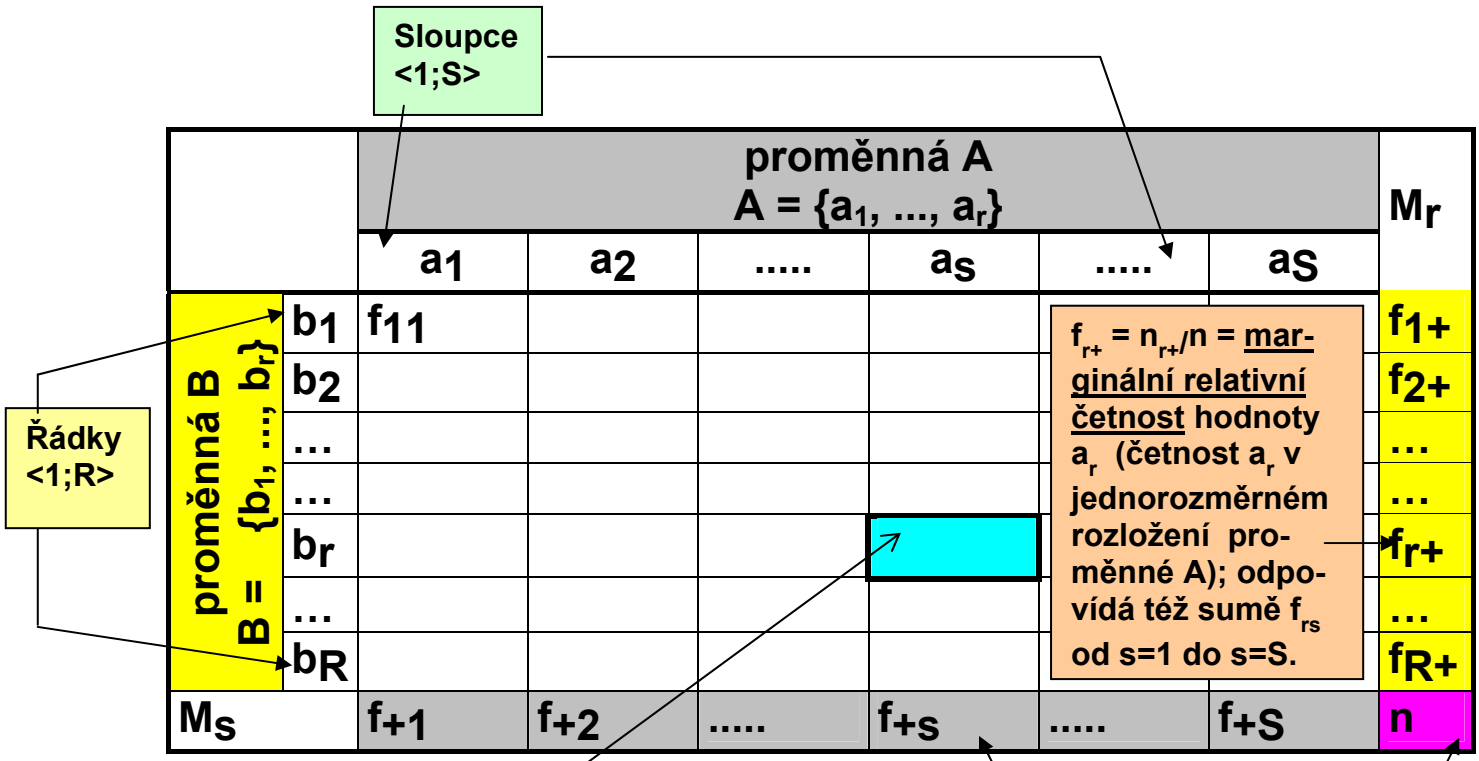

- $f_{rs} = n_{rs}/n$ = relativní četnost dvourozměrného rozložení pro dvojici (a_r, b_s); Násobeno 100 jde o procento pole tabulky z celkového počtu pozorování n (CELKOVÉ neboli TOTAL %).
- $f_{s/r} = n_{rs}/n_{r+} = f_{rs}/f_{r+}$ = relativní četnost hodnoty b, v r-tém řádku tabulky (podmíněná četnost pro r-tý řádek, řádková relativní četnost); 100 $f_{s/r}$ % je ŘÁDKOVÉ PROCENTO.
- $f_{r/s} = n_{rs}/n_{+s} = f_{rs}/f_{+s}$ = relativní četnost hodnoty a_r v s-tém sloupci tabulky (podmíněná četnost pro s-tý sloupec, sloupcová relativní četnost); 100 $f_{r/s}$ % je SLOUPCOVÉ PROCENTO.

Poznámka: Hodnoty f_{r+} a f_{+s} se mohou lišit od původních jednorozměrných empirických rozložení díky vlivu vynechaných dat (missing date).

JEN ABSOLUTNÍ ČETNOSTI?

vztah mezi významem „porozumění a snášenlivosti (Q40_8)“ a „vzájemné úcty a uznání (Q40_4)“ pro úspěšnost manželství

Count

		Q40_8 Porozumění manželů			
		1 velmi důležité	2 spíše důležité	3 nepříliš důležité	Total
Q40_4 Úcta a uznání manželů	1 velmi důležité	1483	168	6	1657
	2 spíše důležité	132	93	1	226
	3 nepříliš důležité	5	4	2	11
Total		1620	265	9	1894

RELATIVNÍ PROCENTA SLOUPCŮ NEBO ŘÁDKŮ?

Vztah mezi významem „porozumění a snášenlivosti (Q40_8)“ a „vzájemné úcty a uznání (Q40_4)“ pro úspěšnost manželství:
OBOJÍ: Nelze jednoznačně určit závisle proměnnou a nezávisle proměnnou! SYMETRICKÝ VZTAH.

			Q40_8 Porozumění manželů			
			1 velmi důležité	2 spíše důležité	3 nepříliš důležité	Total
Q40_4 Úcta a uznání manželů	1 velmi důležité	Count	1483	168	6	1657
		% within Q40_4 Úcta a uznání manželů	89.5%	10.1%	.4%	100.0%
		% within Q40_8 Porozumění manželů	91.5%	63.4%	66.7%	87.5%
	2 spíše důležité	Count	132	93	1	226
		% within Q40_4 Úcta a uznání manželů	58.4%	41.2%	.4%	100.0%
		% within Q40_8 Porozumění manželů	8.1%	35.1%	11.1%	11.9%
	3 nepříliš důležité	Count	5	4	2	11
		% within Q40_4 Úcta a uznání manželů	45.5%	36.4%	18.2%	100.0%
		% within Q40_8 Porozumění manželů	.3%	1.5%	22.2%	.6%
Total		Count	1620	265	9	1894
		% within Q40_4 Úcta a uznání manželů	85.5%	14.0%	.5%	100.0%
		% within Q40_8 Porozumění manželů	100.0%	100.0%	100.0%	100.0%

„Co by měla společnost zajišťovat, aby byla považována za spravedlivou (Q76_1)“ versus „společenská skupina (Q110C):
ŘÁDKOVÉ. Určíme závisle proměnnou a nezávisle proměnnou (tou je řádková proměnná Q110C)! ASYMETRICKÝ VZTAH.

			Q76_1 Zabránit velkým nerovnostem					
			1 velmi důležité	2	3	4	5 ani trochu důležité	Total
Q110C Spolecenska skupina	1 nizsi	Count	142	79	32	15	9	277
		% z Q110C	51.3%	28.5%	11.6%	5.4%	3.2%	100.0%
	2 nizsi stredni	Count	173	182	144	78	33	610
		% z Q110C	28.4%	29.8%	23.6%	12.8%	5.4%	100.0%
	3 stredni	Count	221	215	240	120	55	851
		% z Q110C	26.0%	25.3%	28.2%	14.1%	6.5%	100.0%
	4 vyssi stredni	Count	22	18	42	36	16	134
		% z Q110C	16.4%	13.4%	31.3%	26.9%	11.9%	100.0%
Total		Count	558	494	458	249	113	1872
		% z Q110C	29.8%	26.4%	24.5%	13.3%	6.0%	100.0%

PAMATUJME SI! pro asymetrické vztahy
Spočítáme-li řádková procenta (nezávislá proměnná v řádcích jako v tomto případě), interpretujeme je ve sloupcích.
Spočítáme-li sloupcová procenta (nezávislá proměnná ve sloupcích), interpretujeme je v řádcích.

MÁ SMYSL POUŽÍVAT CELKOVÝCH PROCENT?

KOLIK JE V SOUBORU PŘÍPADŮ URČITÉHO TYPU? KONKRÉTNĚ (kolik manželských párů pochází z úplných rodin)?

			N7REC typ rodiny nevesty - recod			
			1 neuplna	2 uplna opakovana	3 uplna puvodni	**Total**
Z2REC typ rodiny zenicha-recod	1 neuplna	Count	7		20	**27**
		Total %	**2,7%**		**7,8%**	**10,5%**
	2 uplna opakovana	Count	4	2	14	**20**
		Total %	**1,6%**	**,8%**	**5,4%**	**7,8%**
	3 uplna puvodni	Count	21	29	161	**211**
		Total %	**8,1%**	**11,2%**	**62,4%**	**81,8%**
Total		Count	**32**	**31**	**195**	**258**
		Total %	**12,4%**	**12,0%**	**75,6%**	**100,0%**

Párů, kde ženich a nevěsta pocházejí oba z úplných původních rodin, je v našem souboru 62,4% (párů, kde oba pocházejí z neúplných rodin, je zde 2,7% ...). Párů, ve kterých pochází ženich z úplné původní rodiny je zde 10,5% případů (co se týče nevěst, je to 12,4% případů ....

MÁ SMYSL POUŽÍVAT CELKOVÝCH PROCENT?

KOLIK JE V SOUBORU PŘÍPADŮ URČITÉHO TYPU? KONKRÉTNĚ (kolik, respektive jaký podíl, mužů či žen si myslí, že „žena musí mít děti, aby se naplnilo její poslání“?)

			Q84 Pohlaví		
			1 muž	2 žena	Total
Q42 Žena musí mít děti, aby splnila poslání	1 ano	Count	363	432	795
		% of Total	20.1%	24.0%	44.1%
	2 není to nutné	Count	500	508	1008
		% of Total	27.7%	28.2%	55.9%
Total		Count	863	940	1803
		% of Total	47.9%	52.1%	100.0%

Muži, kteří si myslí že „ŽENA MUSÍ MÍT DĚTI, ABY SE NAPLNILO JEJÍ POSLÁNÍ“ představují 20 % souboru a ženy 24 % souboru. POZOR: Nikoliv 20 % mužů či 24 % žen (abychom zjistili podíl tohoto názoru mezi muži a ženami, museli bychom vypočítat sloupcové četnosti), proto nemůžeme tato procenta srovnávat. To, že je v souboru více žen než mužů s tímto názorem může být dáno i tím, že je v něm vůbec více žen! CELKEM SI TO V NAŠEM SOUBORU MYSLÍ 44% OSOB.

POZOROVANÉ A OČEKÁVANÉ HODNOTY A RESIDUÁLY

		proměnná A						
		a_1	a_2	.....	a_S	.....	a_S	M_r
proměnná B	b_1	f_{11}						f_1+
	b_2							f_2+
	…							…
	…							…
	b_r							f_r+
	…							…
	b_R							f_R+
M_S		$f+1=100$	$f+2=100$	.... =100	$f+s=100$	.... =100	$f+S=100$	$n=100$

- **EXPECTED COUNT = očekávané četnosti, počet jednotek, který by byl v tomto políčku při nezávislosti obou znaků (náhodné rozložení).**
- **RESIDUAL = rozdíl mezi pozorovaným počtem jednotek, které mají příslušnou empirickou kombinaci hodnot obou znaků a očekávanou četností. Residuály se dále standardizují a používají se v adjustované (na velikost tabulky) podobě.**
- **STD. RESIDUAL = Standardizované chi^2 residuály, neboli residuály vydělené druhou odmocninou očekávaných hodnot.**
- **ADJUSTED RESIDUAL = Adjustované residuály (tak, aby měly přibližně normální rozložení s průměrem = 0 a standardní odchylkou rovnou 1).**

OČEKÁVANÉ HODNOTY PRO JEDNOTLIVÁ POLÍČKA

celková četnost v řádku (marginální řádková četnost)

celková četnost ve sloupci (marginální sloupcová četnost)

očekávané hodnoty = $\frac{(R) \cdot (C)}{N}$

celkový počet případů ¨v souboru

POZOROVANÉ A OČEKÁVANÉ HODNOTY A RESIDUÁLY

			Q84 Pohlaví		
			1 muž	2 žena	Total
Q30_1 Bůh existuje	1 ano	Count	253	379	632
		Expected Count	309.0	323.0	632.0
		Residual	-56.0	56.0	
		Std. Residual	-3.2	3.1	
		Adjusted Residual	-5.7	5.7	
	2 ne	Count	541	451	992
		Expected Count	485.0	507.0	992.0
		Residual	56.0	-56.0	
		Std. Residual	2.5	-2.5	
		Adjusted Residual	5.7	-5.7	
Total		Count	794	830	1624
		Expected Count	794.0	830.0	1624.0

INTERPRETACE KONTINGENČNÍ TABULKY Z ROZLOŽENÍ ČETNOSTÍ

1. JE OBVYKLE PROVÁDĚNA Z ŘÁDKOVÝCH ČI SLOUPCOVÝCH RELATIVNÍCH ČETNOSTÍ (PROCENT). Na rozdíl od absolutních hodnot nám totiž umožňují vzít v úvahu počet případů v souboru.

   Příklad:
   Údaj o tom, že 20 žen v souboru má vysokoškolské vzdělání, zatímco mezi muži je vysokoškoláků jen 6 (ženy s vysokoškolským vzděláním se zde vyskytují častěji) může dostat zcela jiný výklad, uvědomíme-li si, že žen je v souboru 100 a mužů jen 10 (vysokoškolské vzdělání má v souboru 60% mužů, zatímco jen 20% žen).

2. URČÍME, KTEROU PROMĚNNOU BUDEME POVAŽOVAT ZA NEZÁVISLOU. Případy, jako je vztah pohlaví a spokojenosti s platem, jsou jednoduché: na pohlaví závisí spokojenost s platem, spokojenost s platem pohlaví ovlivnit nemůže. V jiných případech je to složitější (nezávisle proměnnou určujeme arbitrárně).

   Příklad:
   Preference soukromého vlastnictví před státním některými lidmi může vést k tomu, že tito lidé volí pravicové strany a ne levicové (a naopak).
   Vede však tato preference k volební preferenci, nebo je to naopak volební preference, která je příčinou preference určitého typu vlastnictví?

- Pro analýzu VOLÍME PŘIMĚŘENÉ RELATIVNÍ ČETNOSTI (sloupcové, jsou-li varianty nezávisle proměnných ve sloupcích a řádkových, jsou-li v řádcích).
- POROVNÁME PROCENTA pro jednotlivé varianty nezávisle proměnné pro každou variantu závisle proměnné.
  - Je-li nezávisle proměnná ve sloupcích, porovnáváme tyto sloupcová % v každém řádku.
  - Je-li nezávislá proměnná v řádcích, porovnáváme řádková % v každém sloupci.

Příklad: Spokojenost s platem u mužů a žen (vztah mezi pohlavím a spokojeností s platem)

absolutní četn. řádková % sloupcová % celková %		PROMĚNNÁ A pohlaví muži	 ženy	CELKEM
PROMĚNNÁ B - spokojenost	spokojen/a	30 52% 25% 16%	28 48% 40% 14%	58 100%
	střed	30 50% 25% 16%	30 50% 43% 16%	60 100%
	nespokojen/a	60 83% 50% 32%	12 17% 17% 6%	72 100%
CELKEM		120 100%	70 100%	190

Muži jsou méně spokojeni s platem než ženy, jak lze zjistit porovnáním sloupcových četností v jednotlivých řádcích (spokojených je mezi muži 25%, zatímco mezi ženami 40%).

Pokud bychom chtěli interpretovat řádkové četnosti, dozvíme se jen, že mezi spokojenými je 52% mužů a 48% žen, což nedává moc smyslu, protože počet žen a mužů je v souboru rozdílný. Museli bychom jedině porovnat podíl spokojených mužů (resp. žen) s jejich podílem v celém souboru.

Všimněte si, že skutečně potřebujeme nikoliv absolutní, ale RELATIVNÍ ČETNOSTI (spokojených mužů je v absolutním počtu prakticky stejně jako spokojených žen).