

Kappa, jako všechny koeficienty pro pořadové znaky, nabývá rozsahu hodnot od -1 do $+1$. Hodnota 1 znamená perfektní souhlas, hodnota 0 znamená takový počet shod, který odpovídá náhodné shodě pozorovatelů (Hendl, 2004, s. 232), hodnota -1 perfektní nesouhlas. Hodnotu koeficientu *kappa* pro naši situaci ukazuje výstup 9.5b a očividně její hodnota $0,17$ značí velmi nízkou míru souhlasu – de facto se jedná o hodnotu, která se blíží náhodnému rozložení na diagonále. Česká veřejnost se tedy při vyjadřování důvěry poslancům a senátorům ve svých postojích neshoduje. Z frekvencí jednotlivých proměnných nebo jejich průměrů pak vyplývá, že o něco vyšší důvěru požívala Poslanecká sněmovna.

Symmetric Measures

	Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Measure of Agreement Kappa	,165	,018	10,064	,000
N of Valid Cases	1748			

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

Výstup 9.5b Koeficient souhlasu pro důvěru v Parlament a Senát

V literatuře se vyskytl návod, jak interpretovat hodnoty tohoto koeficientu: *kappa*, která je nižší než $0,40$, indikuje velmi nízkou míru souhlasu (Fleiss, 1981, s. 218). Je to však návod, který nemůže být brán příliš rigidně. Jedním z důvodů je, jak nabádají Sim a Wright (2005), že čím vyšší je počet kategorií sledované proměnné, tím vyšší je možnost, že dojde k nesouhlasu v kategoriích, což se projeví tak, že *kappa* bude mít nižší hodnotu u proměnné s více kategoriemi než u proměnné s méně kategoriemi. Ve výstupu 9.5b si všimněme, že SPSS tiskne i signifikanci tohoto koeficientu, statistikové však upozorňují, že testovat nulovou hypotézu nemá v případě úloh o shodě smysl.

9.5 Míra souvislosti pro intervalové znaky

Souvislost mezi dvěma znaky intervalovými se měří prostřednictvím jednoho jediného koeficientu – **Pearsonova koeficientu lineární korelace** (značíme symbolem r). Vypočítá se prostřednictvím kovariance, to je variance (rozptylu) pro dvě proměnné, kdy každou odchylku od průměru jedné proměnné ($x_i - \bar{x}$) násobíme odchylkou od průměru druhé proměnné ($y_i - \bar{y}$), tyto odchylky sečteme a podělíme $N - 1$:

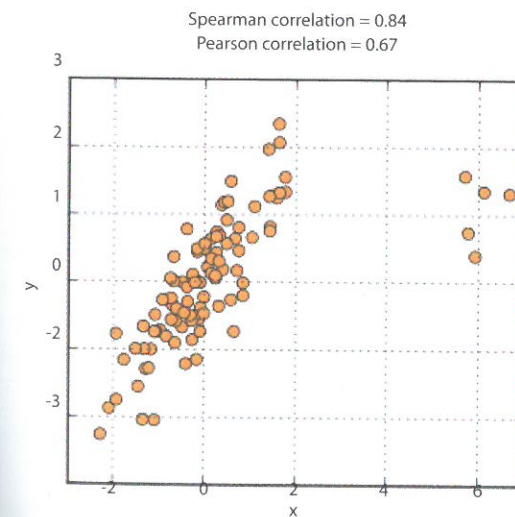
$$\text{cov}(x, y) = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{N - 1}$$

Tuto kovarianci standardizujeme (podělíme součinem směrodatných odchylek obou proměnných). Vzorec má pak tuto podobu:

$$r = \frac{\text{COV}_{xy}}{S_x S_y}$$


Pearsonův koeficient je koeficientem symetrickým, nabývá hodnot od -1 do $+1$ a fakt, že je to koeficient lineární korelace znamená, že dokáže zachytit a změřit pouze lineární vztah mezi dvěma proměnnými. Lineární vztah nastává tehdy, když s měnicími se hodnotami jedné proměnné se proporcionálně mění hodnoty druhé proměnné – kdybychom hodnoty obou proměnných zaznamenali do dvourozměrného bodového grafu, body budou ležet na přímce. Pokud zjistíme, že Pearsonův koeficient má hodnotu 0 , neznamená to ještě, že mezi sledovanými proměnnými není vztah – nula zde indikuje, že vztah nemá lineární podobu (totéž indikuje nula u Spearmanova koeficientu). Jelikož je výpočet korelačního koeficientu r založen na rozptylu (a tudíž odchylkách od průměru), je jeho hodnota citlivá na odlehlé hodnoty – pro srovnání Spearmanův koeficient, který se vypočítává podle stejné rovnice jako r , kdy však hodnoty proměnných x a y tvoří pořadí, na odlehlé hodnoty citlivý není.

Ilustruje to následující obrázek (viz obr. 9.4), na němž je pro dané rozložení srovnávána hodnota korelace Pearsonova a Spearmanova: Pearsonova korelace ($r = 0,67$) je nižší než korelace Spearmanova ($r_s = 0,84$). Rozdíl je způsoben odlehlými hodnotami v pravé části obrázku.



Obr. 9.4 Pearsonova a Spearmanova korelace pro data s odlehlými hodnotami

A ještě jedno zajímavé srovnání si uvedme: na obr. 9.5 je podobné srovnání hodnot těchto dvou koeficientů v případě, kdy vztah má esovitou, to je nelineární, avšak monotónní podobu. Spearmanův koeficient má hodnotu $r_s = 1,00$, zatímco Pearsonovo $r = 0,88$. Tyto příklady mimochodem pěkně ukazují, jak je důležité si při měření souvislosti u pořadových nebo intervalových proměnných nechat udělat bodový graf, z něhož zjistíme, jaký má hledaný vztah průběh – což je důležité jak pro nasazení příslušného koeficientu, tak také pro jeho interpretaci.

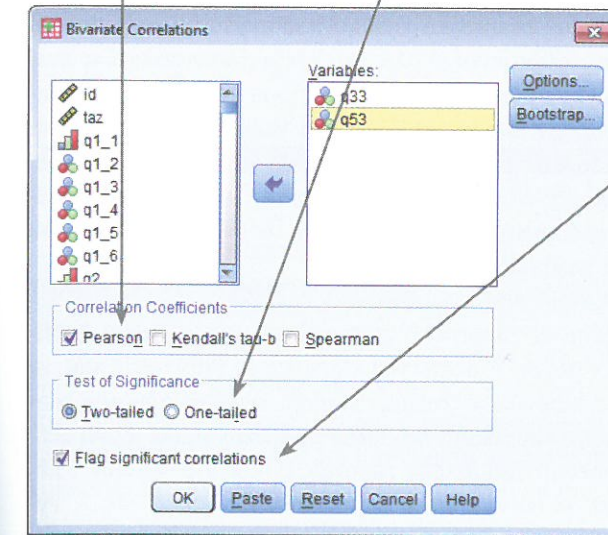


Obr. 9.5 Pearsonova a Spearmanova korelace pro data s odlehlými hodnotami

Pearsonův koeficient korelace zpravidla vypočítáváme v SPSS pomocí jiné procedury než předchozí koeficienty.²²² Z předcházejících kapitol již víme, že intervalové znaky se mimo jiné vyznačují tím, že mají dlouhé stupnice měření (např. proměnná věk má u dospělých respondentů více než 60 kategorií, příjem může mít desetitisíce kategorií, levo-pravá politická orientace může mít deset kategorií atd.). Bylo by proto nesmyslné nechat vytvářet pro takovéto znaky tabulku třídění II. stupně (*Crosstabs*). Například kdybychom třídili proměnnou *levo-pravá politická orientace* měřenou na desetibodové stupnici s proměnnou *důležitost Boha v životě* jedince měřenou rovněž na desetibodové stupnici, vznikne tabulka o 10 sloupcích a 10 řádcích (takže by měla 100 políček), která se nedá jednoduše smysluplně zobrazit ve výstupu, jednoduše se nedá ani smysluplně interpretovat. Z tohoto důvodu má SPSS nastavenou možnost vypočítat Pearsona (ale i Spearmana a Kendallovo *tau*) bez tabulky *Crosstabs*. Je jí procedura *Correlate*, která tiskne jako výstup **matici korelací**.

²²² Jistě jste si v obr. 9.1b všimli, že Pearsonův koeficient je zabudován i v proceduře *Crosstabs*. Tento způsob výpočtu má smysl použít tehdy, když intervalové proměnné mají krátké stupnice měření. Což by např. bylo v případě, kdybychom hledali souvislost mezi počtem dětí (hodnoty této proměnné se obvykle pohybují od 0 do 4) a mírou anomie (tato stupnice nabývá hodnot od 0 do 5). Ale ani při *Crosstabsu* není třeba tabulky vytvářet. Když zaškrtneme požadavek *Suppress tables*, objeví se pouze požadované koeficienty.

Procedura: *Analyze – Correlate – Bivariate* – proměnné, jejichž vztahy hledáme – volba koeficientů – volba jedno či dvoustranného testu signifikance – zvýrazní signifikantní korelace.



Obr. 9.6 Dialogové okno pro zadání výpočtu matice korelací

Příklad 9.4

Existuje v datech EVS statistická souvislost mezi politickou orientací měřenou na levo-pravém kontinuu (*q53*) a názorem na důležitost Boha v životě jedince (*q33*)?

Řešení: Zadání tohoto výpočtu ukazuje obr. 9.6. Výstup vypadá následovně (viz výstup 9.6). Výsledná matice korelací má vždy podobu čtvercové tabulky obsahující tolik řádků a sloupců, kolik proměnných vstupuje do analýzy. Všimněte si, že korelace proměnných se sebou samými jsou umístěny na diagonále tabulky a jsou vždy rovny 1.

		Correlations	
		Q33 Bůh - důležitost v životě	Q53 Levice - pravice
Q33 Bůh - důležitost v životě	Pearson Correlation	1,000	,147**
	Sig. (2-tailed)	,	,000
	N	1846	1711
Q53 Levice - pravice	Pearson Correlation	,147**	1,000
	Sig. (2-tailed)	,000	,
	N	1711	1758

** Correlation is significant at the 0.01 level (2-tailed).

Výstup 9.6

Pozn. Žluté zvýraznění políčka je provedeno z didaktických důvodů, SPSS to sám o sobě nedělá.