

4.6 Kanonická korelační analýza CCA

Zaměření metody CCA

Navržena v 1935 Hotellingem při hledání lineární kombinace jedné skupiny znaků $x = (x_1, \dots, x_q)$, korelující s lineární kombinací druhé skupiny $y = (y_1, \dots, y_p)$.

Cíl: Hledají se *lineární kombinace znaků* obou skupin, tj. hypotetických kanonických proměnných, které vedou k maximálním vzájemným korelacím.

Vznikne *nový souřadnicový systém* vzájemně ortogonálních složek.

V 1. kroku se hledá lineární kombinace x a lineární kombinace y , jejichž korelace je maximální. Tyto lineární kombinace tvoří první složky souřadnicových systémů **kanonických proměnných** pro x a y .

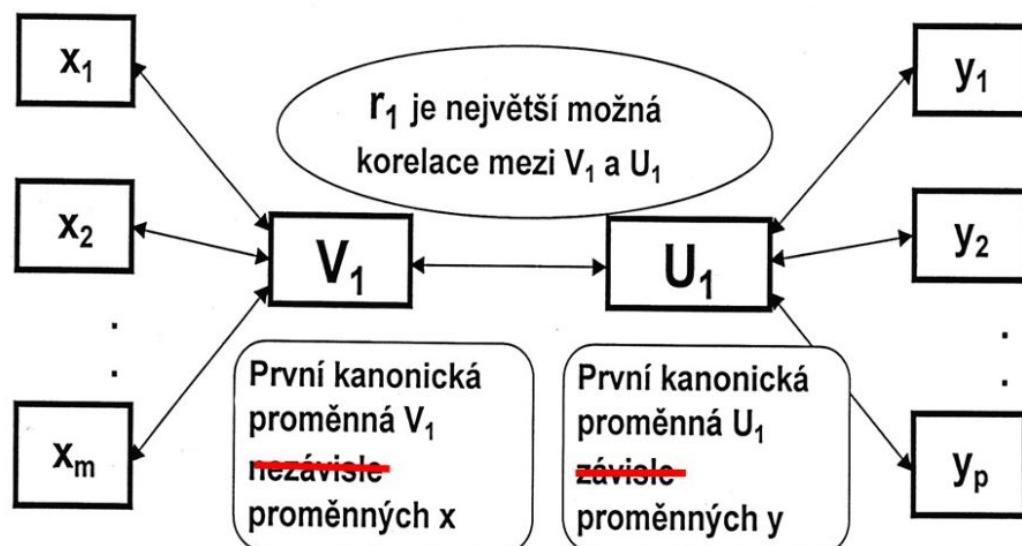
V dalších krocích se hledají *další lineární kombinace x a y* čili kanonické proměnné, které mají maximální vzájemnou korelaci a přitom jsou nekorelované s prvními kanonickými proměnnými.

Soubor nezávisle proměnných x

$$V_1 = b_1 x_1 + b_2 x_2 + \dots + b_m x_m$$

Soubor závisle proměnných y

$$U_1 = a_1 y_1 + a_2 y_2 + \dots + a_p y_p$$

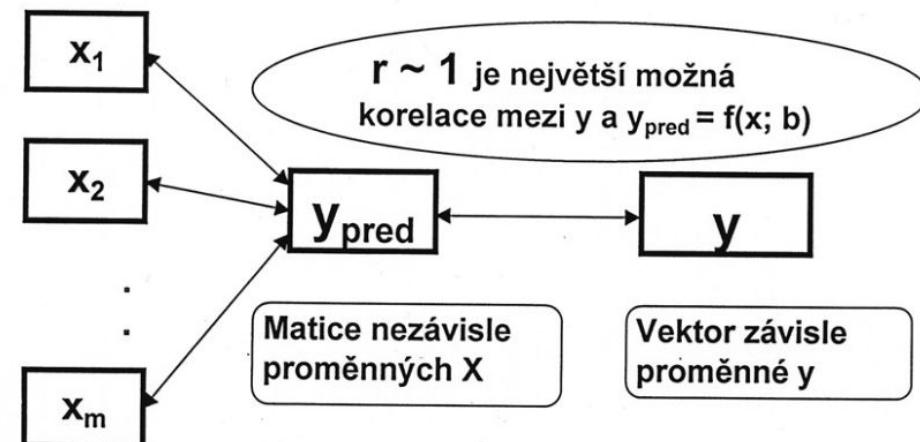


Soubor nezávisle proměnných x

$$y_{\text{pred}} = b_1 x_1 + b_2 x_2 + \dots + b_m x_m$$

Závisle proměnná y

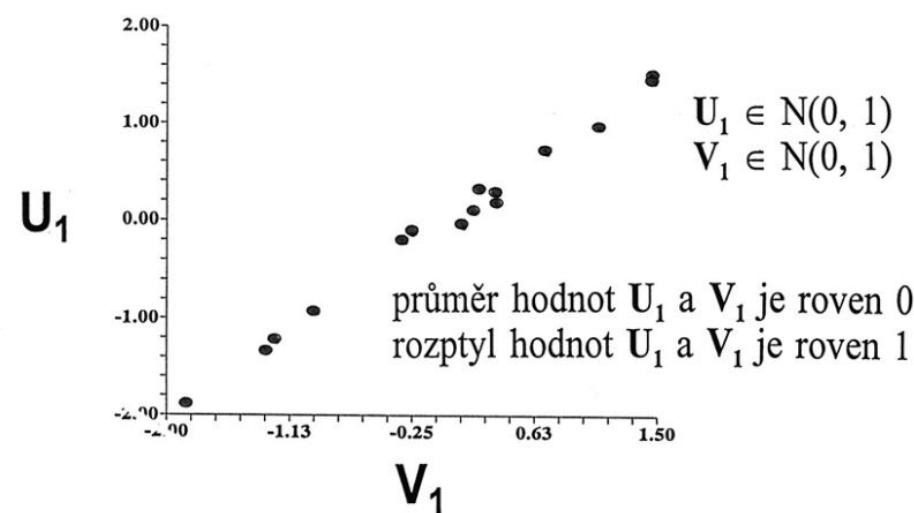
$$y$$



nejlepší odhad

parametrů b_1, b_2, \dots, b_m

Nalézt nejlepší odhad koeficientů a a b , aby pro všech n objektů výkazovaly U_1 a V_1 maximální párový korelační koeficient.

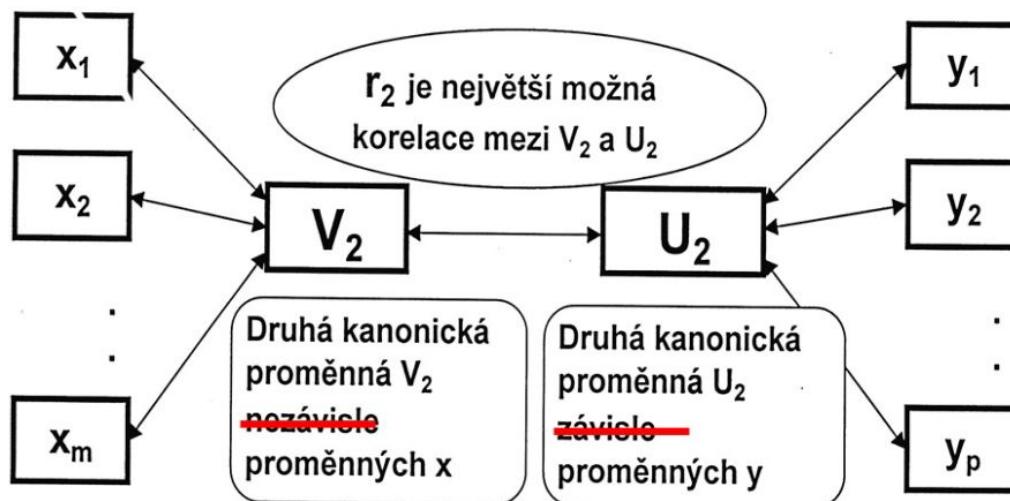


Soubor ~~nezávisle~~ proměnných x

$$V_2 = b_1 x_1 + b_2 x_2 + \dots + b_m x_m$$

Soubor ~~závisle~~ proměnných y

$$U_2 = a_1 y_1 + a_2 y_2 + \dots + a_p y_p$$



Podstata metody CCA

Vytváříme **vztah** mezi skupinami znaků $\mathbf{x} = (x_1, x_2, \dots, x_p)^T$ a $\mathbf{y} = (y_1, y_2, \dots, y_q)^T$.

Lze předpokládat, že všechny znaky jsou **centrované**.

V kanonické korelační analýze se tvoří (*levá*) **kanonické proměnná**

$$U_1 = a_1 y_1 + a_2 y_2 + \dots + a_q y_q \quad \text{ze znaků } \mathbf{y}$$

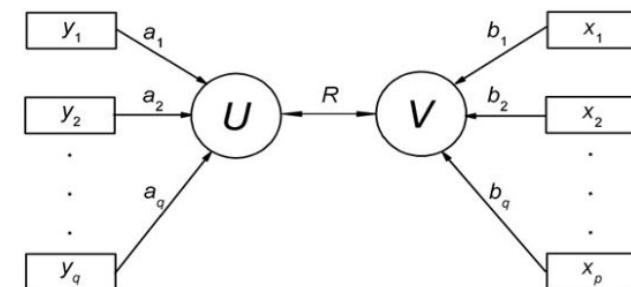
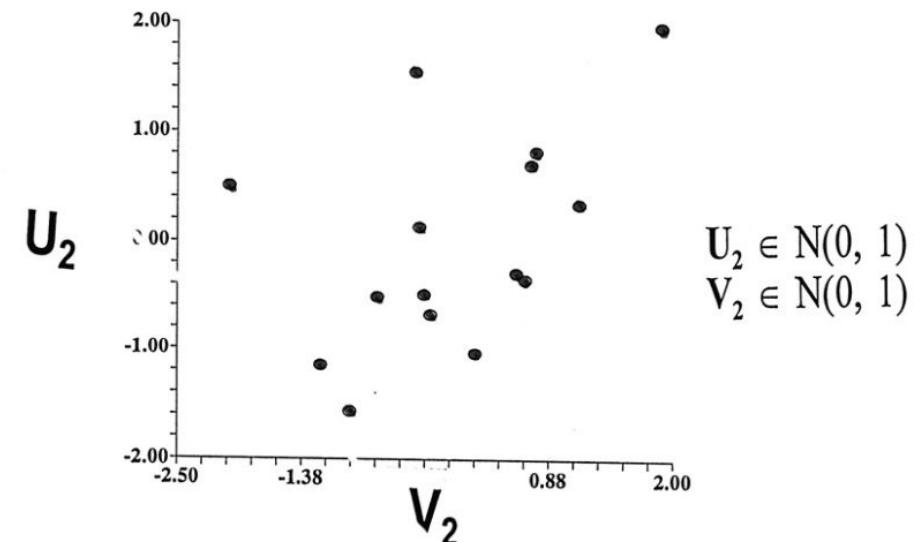
a (*pravá*) **kanonická proměnná**

$$V_1 = b_1 x_1 + b_2 x_2 + \dots + b_p x_p \quad \text{ze znaků } \mathbf{x}.$$

Hledají se koeficienty a_i a b_i tak, aby kanonické proměnné U_1 a V_1 vykazovaly maximální **párový korelační koeficient R**.

V druhém kroku se pak hledají **další kanonické proměnné U_2 a V_2** , které mají druhý největší korelační koeficient r_2 a za podmínky, že U_2 a V_2 jsou nekorelované s prvními kanonickými proměnnými U_1 a V_1 .

Naležt nejlepší odhadky koeficientů a a b , aby pro všechn n objektů vykazovaly U_2 a V_2 druhý největší párový korelační koeficient.



Model kanonické korelační analýzy kanonických proměnných: U značí závislou kanonickou proměnnou a V nezávislou kanonickou proměnnou.

Korelace R mezi U_1 a V_1 se nazývá **první kanonická korelace**.

Je to největší možná korelace mezi lineárními kombinacemi znaků \mathbf{y} a lineárními kombinacemi znaků \mathbf{x} .

Představuje analogii k vícenásobnému korelačnímu koeficientu ve vícenásobné lineární regresi. Rozdíl je v tom, že zde existuje několik znaků \mathbf{y} a je nutné navíc hledat optimální lineární kombinaci mezi nimi.

PŘÍKLAD 6.1 Spokojenost v práci ovlivňuje některé domény spokojenosti v životě

Byl analyzován dotazník o **10** fiktivních doménách spokojenosti v práci, doma v rodině a v zálibách a koníčích v odpovědích vyplněný **100** respondenty. Cílem je vyšetřit, jak ovlivňují **3 domény** spokojenosti v práci na jedné straně zbývajících **7 domén** spokojenosti na druhé straně. Pokusíme se spokojenost v práci chápát jako nezávisle proměnnou V a spokojenost v ostatních jako závisle proměnnou U .

○ **Data:** Zdrojová matice dat *Spokojenost* je analyzována programy STATISTICA a NCSS2002.

○ **Řešení:** Kanonická korelační analýza je založena na korelační matici znaků.

1. Exploratorní analýza dat EDA: Abychom vyšetřili rozdělení znaků a nalezli vybočující objekty, je vhodné sestrojit dva EDA-grafy pro všechny znaky, a to krabicový graf a maticový diagram.

Druhá kanonická proměnná V_2 je lineární kombinací x a jí odpovídající druhá kanonická proměnná U_2 je lineární kombinací y .

Koefficienty a a b jsou nyní vybrány tak, že současně platí:

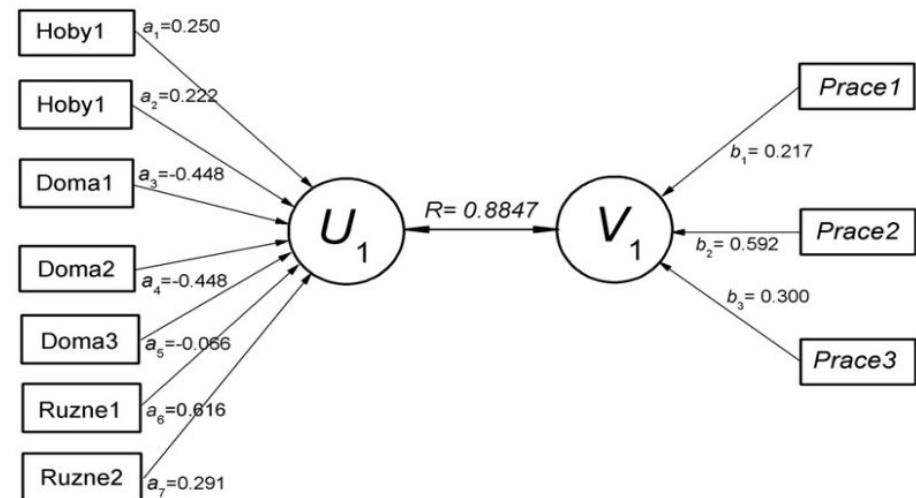
1. V_2 je nekorelované s V_1 a U_1 .
2. U_2 je nekorelované s V_1 a U_1 .

V_2 a U_2 mají maximální možnou korelací R , která je ale **nutně menší** než u V_1 a U_1 .

V dalších krocích se určují **další** kanonické proměnné U_3 a V_3 , U_4 a V_4 atd.

Maximální počet kanonických korelací je roven menšímu ze dvou čísel p a q , když p je počet znaků x a q je počet znaků y .

Interpretace: Kanonické proměnné je nutno interpretovat jako hypotetické proměnné, které je často obtížné fyzikálně vysvětlit.



První pár kanonických korelačních proměnných U_1 a V_1 dostatečně popisuje závislost 7 znaků *Hoby1*, *Hoby2*, *Doma1*, *Doma2*, *Ruzne1*, *Ruzne2* na 3 znacích *Prace1*, *Prace2*, *Prace3* zdrojové matice dat *Spokojenost* (STATISTICA, ORIGIN).

Důležitost každé kanonické proměnné se hodnotí ze dvou hledisek:

- a) Určuje se **intenzita vztahu** mezi kanonickou proměnnou U a původním znakem y a dále kanonickou proměnnou V a znaky x .
- b) Vyjadřuje se **intenzita vztahu** mezi oběma kanonickými proměnnými V a U .

CCA předpokládá pouze **lineární závislost** mezi proměnnými: je třeba vyšetřit grafy každého páru proměnných a prověřit linearitu a odlehle body.

Výpočet: výběrové kanonické proměnné získáme ze dvou datových matic X rozměru $(n \times p)$ a Y rozměru $(n \times q)$, když $p \leq q$.

Společná výběrová kovarianční matice je pak pro případ, že jsou všechny znaky centrované (v odchylkách od průměrů jednotlivých znaků), rovna

$$S = \begin{pmatrix} S_{xx} & S_{xy} \\ S_{yx} & S_{yy} \end{pmatrix} .$$

Kovarianční matice znaků \mathbf{x} je rovna $\mathbf{S}_{xx} = \frac{1}{n-1} \mathbf{X}^T \mathbf{X}$

a **znaků \mathbf{y}** je rovna $\mathbf{S}_{yy} = \frac{1}{n-1} \mathbf{Y}^T \mathbf{Y}$.

Matice kovariancí znaků \mathbf{x} a znaků \mathbf{y} je rovna $\mathbf{S}_{xy} = \frac{1}{n-1} \mathbf{X}^T \mathbf{Y}$.

Platí, že matice $\mathbf{S}_{yx} = \mathbf{S}_{xy}^T$.

Rozkladem matice $(\mathbf{S}_{xx}^{-1} \mathbf{S}_{xy} \mathbf{S}_{yy}^{-1} \mathbf{S}_{yx}) = \mathbf{V} \boldsymbol{\lambda} \mathbf{V}^T$

na vlastní čísla $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ a vlastní vektory $\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_p$ jsou vyčísleny potřebné koeficienty \mathbf{a} koeficienty $\mathbf{b}_i = \mathbf{V}_i$

Koeficienty \mathbf{a}_i se vyčíslí vztahem $\mathbf{a}_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{S}_{yy}^{-1} \mathbf{S}_{xy} \mathbf{b}_i$.

Kanonické proměnné jsou reprezentovány **kanonickými skóre**

$$\mathbf{V} = \mathbf{X} \mathbf{B} \quad \text{a} \quad \mathbf{U} = \mathbf{Y} \mathbf{A},$$

kde \mathbf{B} obsahuje jako sloupce vlastní vektory $\mathbf{V}_i = \mathbf{b}_i$
 \mathbf{A} obsahuje jako sloupce koeficienty \mathbf{a}_i .

K interpretaci kanonických proměnných se počítají také **matice záteží** podle

$$\mathbf{L}_x = \mathbf{S}_{xx} \mathbf{B} \quad \text{a} \quad \mathbf{L}_y = \mathbf{S}_{yy} \mathbf{A}.$$

Pracuje se obvykle s **normovanými znaky**, pak se místo \mathbf{S} užijí matice korelační \mathbf{R} .

Používá se pouze **malý počet** kanonických proměnných, a to menší než $\min(p, q)$.

Pro normované znaky jsou \mathbf{L}_x a \mathbf{L}_y přímo korelačními koeficienty mezi znaky \mathbf{x} a kanonickými proměnnými \mathbf{V} , respektive mezi \mathbf{y} a \mathbf{U} .

Pro centrované znaky se získají korelační matice vynásobením $\mathbf{D}_x^{-1} \mathbf{L}_x$, respektive $\mathbf{D}_y^{-1} \mathbf{L}_y$, kde \mathbf{D} matice obsahující na diagonále směrodatné odchylky znaků.

Test významnosti kanonických korelací

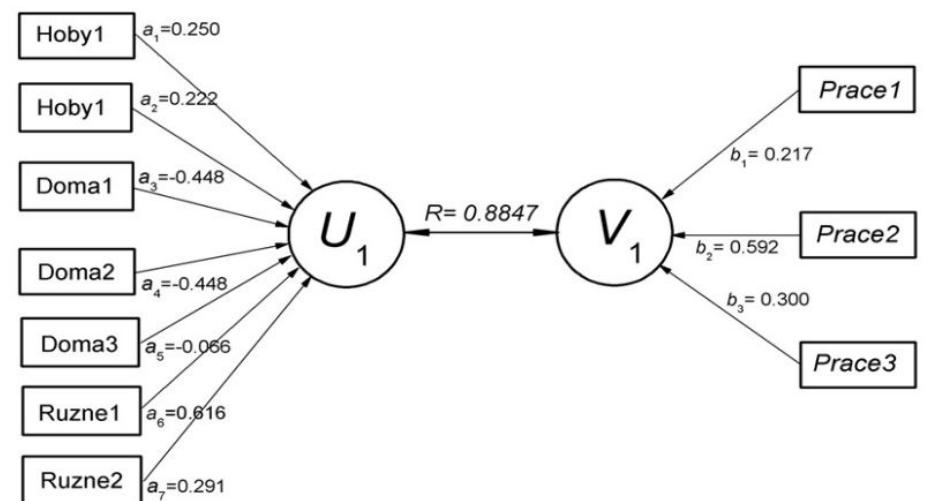
V CCA se vyčíslují:

1. Koeficienty pro všechny kanonické proměnné,
2. Kanonické korelace,
3. Kanonické proměnné pro všechny prvky výběru, zvané *kanonická skóre*.

Test nulové hypotézy H_0 : „ k nejmenších kanonických korelací souboru je rovno nule“.

Dva testy jsou vhodné: **Bartlettův χ^2 -test** a **approximativní F -test**.

Velká hodnota χ^2 a velká hodnota F jsou indikátorem, že ne všechny korelace mezi proměnými v souboru jsou nulové.



První pár kanonických korelačních proměnných U_1 a V_1 dostatečně popisuje závislost 7 znaků *Hoby1, Hoby2, Doma1, Doma2, Ruzne1, Ruzne2* na 3 znacích *Prace1, Prace2, Prace3* zdrojové matici dat *Spokojenost* (STATISTICA, ORIGIN).

Vysvětlení kanonických proměnných

Korelace mezi kanonickými proměnnými a původními znaky: vysvětlují kanonické proměnné, když některé ze znaků ať už ze skupiny x , nebo ze skupiny y jsou navzájem silně vnitřně korelované.

Nazývají se **zátěže kanonických proměnných** nebo **koeficienty kanonické struktury**:

- jsou to korelace mezi každým původním znakem a kanonickou proměnnou,
- jsou užitečné v pochopení vztahu mezi znaky a kanonickými proměnnými.
- je-li skupina znaků v jedné kanonické proměnné nekorelovaná, kanonické zátěže jsou rovny standardizovaným koeficientům kanonické proměnné.
- jsou-li některé ze znaků silně vnitřně korelovány, pak zátěže a koeficienty jsou zcela rozličné.

Například: dva znaky x jsou vysoce kladně korelovány a každý je pozitivně korelován s kanonickou proměnnou. Pak je možné, že jeden koeficient kanonické proměnné bude kladný a jeden záporný, zatímco kanonické zátěže jsou obě kladné, jak by se dalo očekávat.

Grafické pomůcky

Graf závislosti skóre kanonických proměnných U_i na V_j :

Stupeň rozptýlení bodů po ploše je důležitým ukazatelem. Graf je užitečný v odkrývání neobvyklých případů ve výborech jako jsou odlehlé body.

Graf U_1 na V_1 může vést ve zdánlivě nelineární rozptylový diagram nebo eliptický tvar typický pro dvojrozměrné normální rozdělení.

Postup diagnostikování CCA

Je-li počet znaků q ve skupině y roven 1, pak se CCA redukuje na vícenásobnou lineární regresi.

CCA kvantifikuje obecně sílu vztahu mezi dvěma skupinami znaků.

Kanonické proměnné mohou být vysvětlovány podobným způsobem, jako byly vysvětlovány hlavní komponenty nebo faktory.

Analýza redundance

Průměrná hodnota čtverců kanonických zátěží pro první kanonickou proměnnou V_1 poskytuje podíl rozptylu znaků, který je vysvětlen první kanonickou proměnnou.

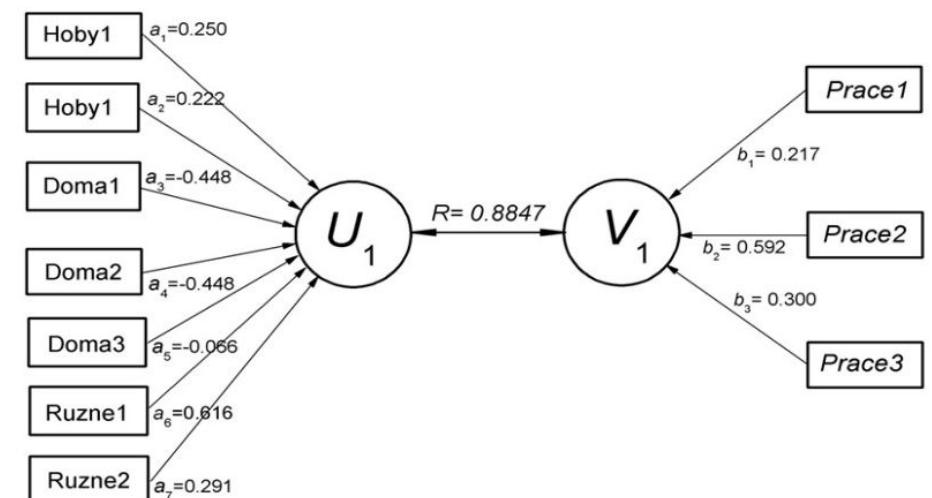
Obdobně pro U_1 a znaky y .

Analýza redundance (nadbytečnosti): podíl rozptylu takto objasněného může být malý, i když jde o vysokou kanonickou koreaci, a to v důsledku jednoho či dvou znaků, které mají hlavní vliv na kanonickou proměnnou.

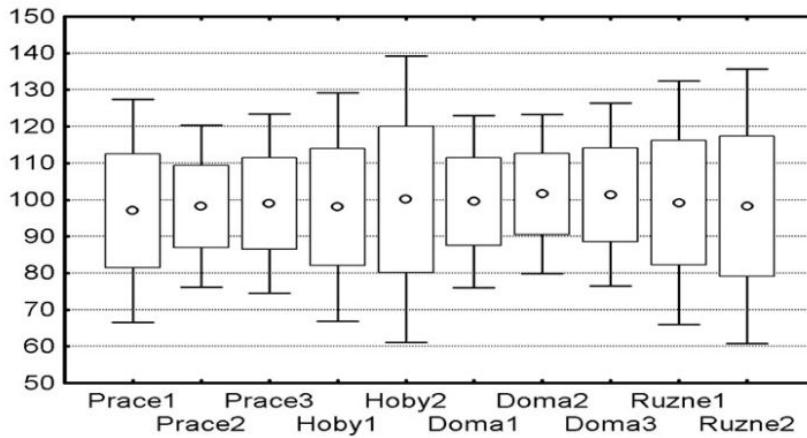
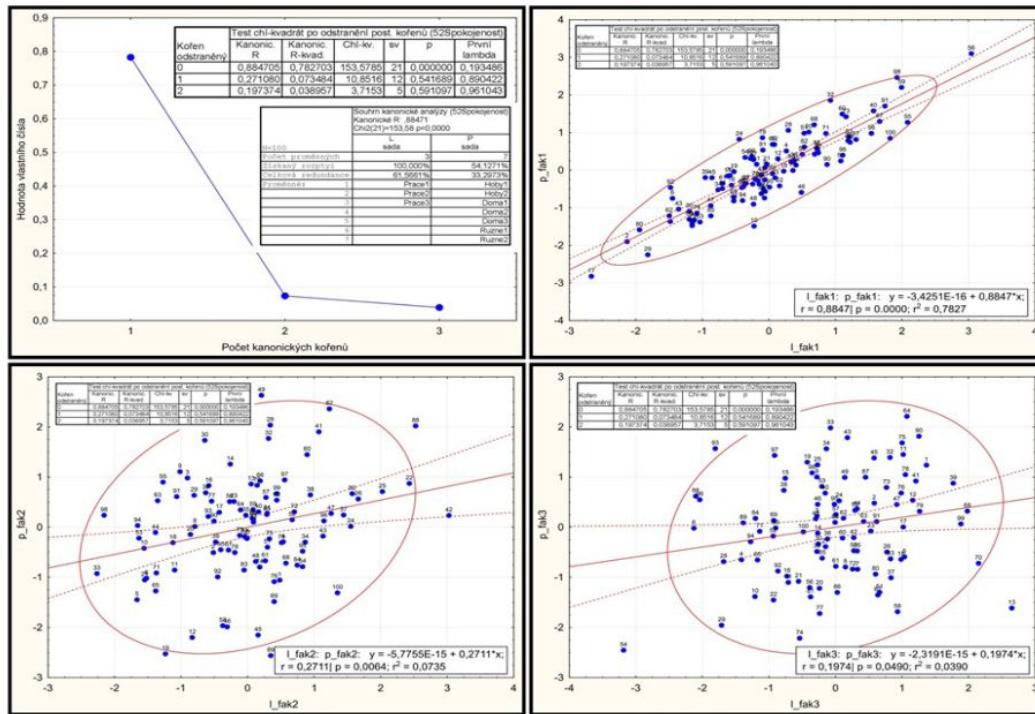
Redundanční index je mírou průměrného podílu rozptylu ve skupině znaků y , který nebyl zahrnut do souboru V .

Je analogický R^2 vícenásobné lineární regresi.

Podobně je možné získat i podíl rozptylu ve skupině znaků x , jež je objasněn všemi proměnnými U .



První páár kanonických korelačních proměnných U_1 a V_1 dostatečně popisuje závislost 7 znaků *Hoby1, Hoby2, Doma1, Doma2, Ruzne1, Ruzne2* na 3 znacích *Prace1, Prace2, Prace3* zdrojové matice dat *Spokojenost* (STATISTICA, ORIGIN).



Krabicové grafy 10 znaků pro 100 respondentů dat Spokojenost (STATISTICA).

Největší proměnlivosti v datech je dosaženo u znaků *Hoby2*, *Prace1*, *Ruzne1*, *Ruzne2*.

I ostatní znaky vykazují dostatečnou proměnlivost.

PŘÍKLAD 6.1 Spokojenost v práci ovlivňuje některé domény spokojenosti v životě

Byl analyzován dotazník o **10** fiktivních doménách spokojenosti v práci, doma v rodině a v zálibách a koníčkách v odpověďích vyplněný **100** respondenty. Cílem je vyšetřit, jak ovlivňují **3 domény** spokojenosti v práci na jedné straně zbývajících **7 domén** spokojenosti na druhé straně. Pokusíme se spokojenost v práci chápát jako nezávisle proměnnou *V* a spokojenost v ostatních jako závisle proměnnou *U*.

○ **Data:** Zdrojová matice dat *Spokojenost* je analyzována programy STATISTICA a NCSS2002.

○ **Řešení:** Kanonická korelační analýza je založena na korelační matici znaků.

1. Exploratorní analýza dat EDA: Abychom vyšetřili rozdělení znaků a nalezli vybočující objekty, je vhodné sestrojit dva EDA-grafy pro všechny znaky, a to krabicový graf a maticový diagram.

2. Korelační koeficienty všech párů znaků zdrojové matice dat:

Vyčíslíme parametry polohy a rozptýlení všech 10 znaků.

Největší proměnlivost v datech vykazuje *Hoby2*, *Prace1*, *Ruzne1*, *Ruzne2*.

	Průměr	Směrodatná odchylka
<i>Prace1</i>	97.03	15.52
<i>Prace2</i>	98.17	11.27
<i>Prace3</i>	98.94	12.49
<i>Hoby1</i>	98.03	15.94
<i>Hoby2</i>	100.11	19.94
<i>Doma1</i>	99.51	11.98
<i>Doma2</i>	101.60	11.06
<i>Doma3</i>	101.37	12.73
<i>Ruzne1</i>	99.16	16.97
<i>Ruzne2</i>	98.22	19.11

Kovarianční matice: 10 znaků zdrojové matice dat *Spokojenost*, týkající se 100 respondentů. Na diagonály jsou uvedeny rozptyly znaků.

	Prace1	Prace2	Prace3	Hoby1	Hoby2	Doma1	Doma2	Doma3	Ruzne1	Ruzne2
Prace1	240.9									
Prace2	113.2	127								
Prace3	126.5	103	155.9							
Hoby1	147.9	123.6	126.7	254.0						
Hoby2	161.3	156.8	156.9	255.7	397.6					
Doma1	26.6	19.3	24.5	102.4	120.8	143.5				
Doma2	24.9	22.7	32.9	111.8	109.4	87.1	122.4			
Doma3	27.2	33.9	40.5	118.3	122.5	90.0	102.9	162.2		
Ruzne1	161.0	135.5	147.8	244.6	274.4	101.3	120.8	126.6	287.9	
Ruzne2	162.8	147.5	160	256.8	288	97.2	125.4	126	272.9	365.2

Korelační matice:

	Prace1	Prace2	Prace3	Hoby1	Hoby2	Doma1	Doma2	Doma3	Ruzne1	Ruzne2
Prace1	1									
Prace2	0.6474	1.0000								
Prace3	.6526	.7319	1.0000							
Hoby1	.5981	.6885	.6369	1.0000						
Hoby2	.5211	0.6978	0.63	.8047	1.0000					
Doma1	.1428	.1434	.1636	0.5364	.5059	1.0000				
Doma2	.1451	.1819	.2383	.6343	.4959	.6577	1.0000			
Doma3	.1378	.0236	.2546	.5828	.4824	.5900	.7306	1.0000		
Ruzne1	.6113	.7086	.6979	.9045	.8110	.4984	0.6436	.5859	1.0000	
Ruzne2	.5489	.6848	.6706	.8432	0.7558	.4247	0.5934	0.5177	0.8414	1

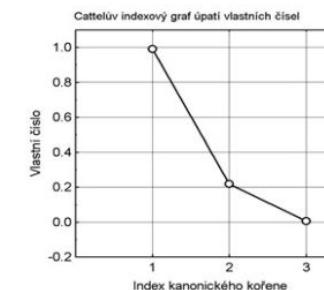
Ve druhém řádku jsou vypočtené hladiny významnosti P . **Platí pravidlo:** je-li $P < \alpha = 0.05$, je hodnota korelačního koeficientu statisticky významná (vyznačena **tučně**).

3. Zadání kanonických proměnných: Volba znaků a zařazení do obou obou kanonických proměnných, U a V , je v CCA čistě formální.

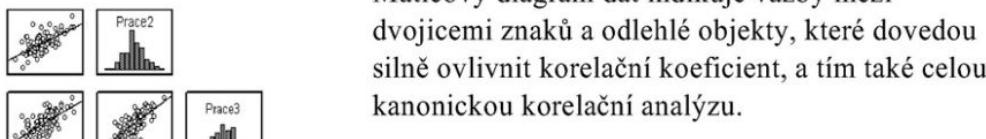
Obě U a V jsou totiž symetrické a stejné, z jejich povahy a obsahu nelze rozlišit.

Znaky do obou proměnných U a V lze libovolně zaměnit a obě proměnné jsou zcela rovnocenné.

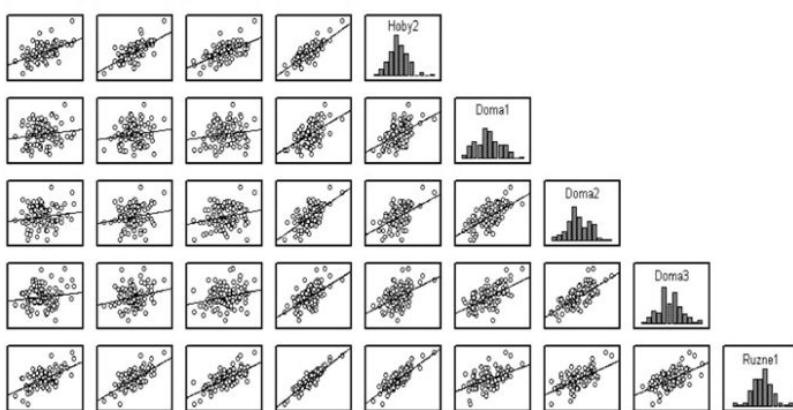
Kritériem počtu vybraných dvojic U a V je Cattelův indexový diagram úpatí vlastních čísel, který zde potvrzuje, že jeden kanonický kořen bude k popisu dat postačovat.



Cattelův indexový diagram úpatí vlastních čísel při kanonické korelace dat 10 znaků pro 100 respondentů dat *Spokojenost* (STATISTICA).



Maticový diagram dat indikuje vazby mezi dvojicemi znaků a odlehlé objekty, které dovedou silně ovlivnit korelační koeficient, a tím také celou kanonickou korelační analýzu.



Maticový diagram 10 znaků pro 100 respondentů dat *Spokojenost* (STATISTICA).

	Pravý soubor nezávislých kanonických proměnných, V	Levý soubor závislých kanonických proměnných, U
Počet znaků	3	7
Rozptyl vyextrahovaný	100.000%	54.1271%
Celková redundance	61.5661%	33.2973%
Znaky:	1 2 3 4 5 6 7	<i>Prace1</i> <i>Prace2</i> <i>Prace3</i> <i>Hoby1</i> <i>Hoby2</i> <i>Doma1</i> <i>Doma2</i> <i>Doma3</i> <i>Ruzne1</i> <i>Ruzne2</i>

Rozptyl vyextrahovaný značí průměrné množství proměnlivosti, vyextrahovaného ze znaků v obou souborech kanonickými proměnnými.

Kanonické proměnné **extrahuji** 100% rozptylu na pravé straně rovnice ze tří znaků *Prace1*, *Prace2*, *Prace3* a 54.13% rozptylu na levé straně rovnice.

Celková redundance ukazuje na **velikost** celkové korelace mezi znaky na pravé straně rovnice 61.6% a na levé straně 33.3%.

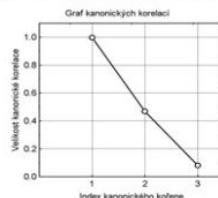
Hodnoty **jsou založeny** na všech kanonických kořenech, totiž znacích na levé straně, jež se týkají domén spokojenosti v práci.

Podobně je 33.3% rozptylu nepracovních domén spokojenosti v životě na levé straně rovnice.

4. Test významnosti kanonických kořenů: vyšetruje, zda všechny tři kanonické kořeny U_1 a V_1 , U_2 a V_2 , U_3 a V_3 jsou statisticky významné.

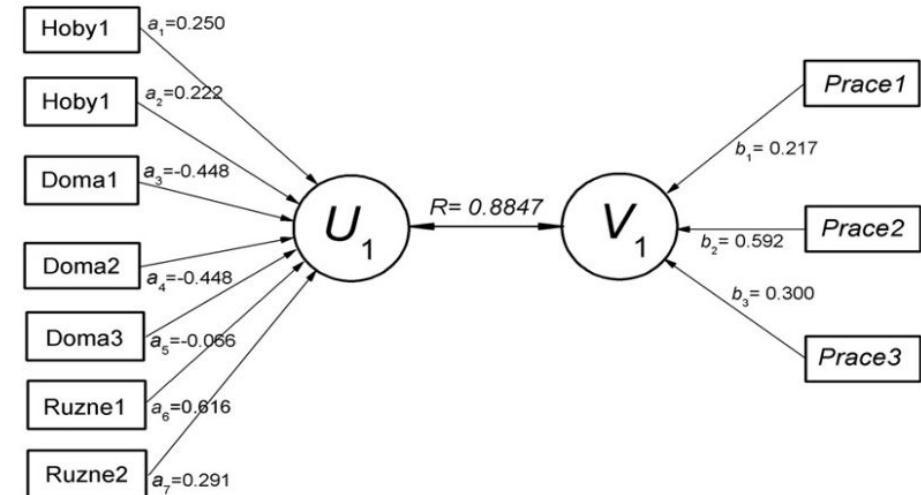
Kanonický korelační koeficient R představuje v datech pouze první kořen U_1 a V_1 čili nejsilnější a nejvýznamnější kanonickou korelací.

Maximální počet kanonických kořenů, které mohou být z dat extrahovány je roven 3.



Hledání potřebných kanonických kořenů z grafu kanonických korelací pro 10 znaků a 100 respondentů dat *Spokojenost* (STATISTICA).

R = 0.8847 je statisticky vysoce významný, protože má vypočtenou hladinu významnosti P menší než $\alpha = 0.05$ a může být vysvětlen jako jednoduchá korelace mezi váženou sumou znaků, odpovídajícími první a nejvýznamnější kanonické proměnné U_1 a V_1 .



První pár kanonických korelačních proměnných U_1 a V_1 dostatečně popisuje závislost 7 znaků *Hoby1*, *Hoby2*, *Doma1*, *Doma2*, *Ruzne1*, *Ruzne2* na 3 znacích *Prace1*, *Prace2*, *Prace3* zdrojové matici dat *Spokojenost* (STATISTICA, ORIGIN).

Diskutujme tři řádky **testování kanonických kořenů**:

1. V prvním řádku nebyl odstraněn žádný kanonický kořen a testy jsou vysoce statisticky významné.
2. V druhém řádku byl první a nejvýznamnější kořen U_1 a V_1 odstraněn a testy už nejsou statisticky významné. Můžeme proto testování ukončit a uzavřít, že statisticky významný je pouze první kanonický kořen U_1 a V_1 .
3. Když by byl i druhý test statisticky významný, postup by pokračoval dál až do takového řádku, kdy by už statistické testy vycházely statisticky nevýznamné.

Vypuštěný kořen	Kanonické R	Kanonické D	χ^2	df	P	Lambda
Žádný	0.885	0.783	153.58	21	0.000	0.193
První U_1 a V_1	0.271	0.073	10.85	12	0.542	0.890
První U_1 a V_1 a druhý U_2 a V_2	0.197	0.039	3.72	5	0.591	0.961

5. Struktura kanonických faktorů a redundancy:

Nadále budeme uvažovat pouze první kanonický kořen U_1 a V_1 .

Jak vysvětlíme tento kanonický kanonický kořen U_1 a V_1 ?

Jak koreluje tento kanonický kořen U_1 a V_1 se znaky v obou souborech?

Vypočítáme proto korelace mezi znaky v každém souboru s kanonickým kořenem.

Tyto korelace se také nazývají **strukturní koeficienty**.

Nesmíme přitom zapomenout, že kanonická proměnná je v každém souboru tvořena jako vážená suma znaků.

Pravý soubor

Faktorová struktura v pravém souboru: pouze první kanonický kořen je statisticky významný a pouze ten budeme vysvětlovat.

Tři znaky spokojenosti $Prace1$, $Prace2$ a $Prace3$ vykazují podstatně vyšší zátěže prvního kanonického faktoru čili vysoké korelace právě s tímto faktorem.

Mírou redundancy je průměrné množství rozptylu vyčísleného pro každý znak prvního kanonického kořene.

Sečtou se čtverce vah kanonických faktorů a vydělí se počtem znaků ve výběru, zde to je 3.

Zátěže čili korelace s kanonickou proměnnou V

	Kořen 1, V_1	Kořen 2, V_2	Kořen 3, V_3
$Prace1$	0.796	-0.575	0.186
$Prace2$	0.953	0.101	-0.287
$Prace3$	0.875	0.217	0.432

$R = 0,885$ (vyjadřuje koreaci mezi U_1 a V_1),

$R\text{-kvad} = 0,783$ (podíl rozptylu zahrnutého do kanonických proměnných)

Kořen odstraněny	Test chí-kvadrát po odstranění jist. kořenu (Factor.st)					
	Kanon. R	Kanon. R-kvad	Chi kv.	sv	p	První lambda
0	0,884705	0,782703	153,5785	21	0,000000	0,193486
1	0,271080	0,073484	10,8516	12	0,541689	0,890422
2	0,197374	0,038957	3,7153	5	0,591097	0,961043

Řádek pro první kanonický kořen.

Kanonické zátěže každého znaku vyjadřují koreaci mezi tímto znakem a dotyčnou kanonickou proměnnou:

Proměnná	Struktura faktorů, L sada (Factor.st)		
	Kořen 1	Kořen 2	Kořen 3
Zaměstnání 1	0,796461	-0,575348	0,186075
Zaměstnání 2	0,952643	0,100725	-0,286926
Zaměstnání 3	0,875390	0,217192	0,431880

$0,796 * 0,796 = 0,6336$
 $0,953 * 0,953 = 0,9082$
 $0,875 * 0,875 = 0,7656$
 Průměr sumy $2,3074 : 3 = 0,7691$ čili **76,91%**
 76,91% vyjadřuje průměrný podíl rozptylu vyčíslený ze 3 znaků, který je vysvětlen první kanonickou proměnnou

Faktor	Získaný rozptyl (Propor.)	
	Získaný rozptyl	Redundance.
Kořen 1	0,769395	0,602208
Kořen 2	0,129448	0,009512
Kořen 3	0,101157	0,003941

Redundanční index = $0,7691 * 0,783 = 0,6022$ je mírou průměrného podílu rozptylu v pravé skupině znaků, který nebyl zahrnut do souboru znaků levé skupiny.

Celková redundancy = celková korelace mezi znaky na pravé straně rovnice se vyčísli: $0,602$ (od 1. kořene) + $0,010$ (od 2. kořene) + $0,004$ (od 3. kořene) = $0,616$ čili **61,6%** vystihuje značně silný vztah mezi třemi znaky souboru.

Stewartův-Loveův index redundancy vyčísluje velikost rozptylu v jedné skupině znaků, který může být objasněn rozptylem ve druhé skupině znaků.

Je součinem dvou složek: **První** je mírou sdíleného rozptylu mezi původním znakem a kanonickou proměnnou a vypočte se jako aritmetický průměr čtverců zátěží L_i^2 .

Druhou složkou je podíl rozptylu v kanonické závislosti proměnné, jenž může být objasněn kanonickou nezávislou proměnnou. Je jí čtverec korelace mezi kanonickou nezávislou proměnnou a kanonickou závislou proměnnou, který je znám jako **čtverec kanonického korelačního koeficientu R^2** .

Redundanční index = $0,7691 * 0,783 = 0,6022$

je mírou průměrného podílu rozptylu v pravé skupině znaků, který nebyl zahrnut do souboru znaků levé skupiny.

Tabulka extrahovaného rozptylu na pravé straně: první kanonický kořen U_1 a V_1 extrahuje průměr okolo 77% rozptylu ze tří položek spokojenosti v práci.

Když vynásobíme hodnotu sdíleného rozptylu mezi kanonickými proměnnými v obou souborech tj. R^2 , obdržíme redundanci.

U znaků na levé straně znaků spokojenosti s nepracovními doménami se vyčíslí okolo 60% rozptylu položek spokojenosti v práci, založených na prvním kanonickém kořenu.

Extrahovaný rozptyl a redundance u kanonické proměnné V		
	Rozptyl	Redundance
Kořen 1, V_1	0.769	0.602
Kořen 2, V_2	0.129	0.010
Kořen 3, V_3	0.101	0.004

Tabulka extrahovaného rozptylu na levé straně.

První kanonický kořen vyčísluje 42% rozptylu znaků na levé straně a okolo 33% rozptylu ostatních spokojeností, založených na prvním kanonickém kořenu.

Je třeba si všimnout, že tato čísla jsou "zatlačena dolů" relativním nedostatkem korelace mezi kanonickou proměnnou a znaky spokojenosti doma v rodině.

Extrahovaný rozptyl a redundance u kanonické proměnné U		
	Rozptyl	Redundance
Kořen 1, U_1	0.417	0.326
Kořen 2, U_2	0.055	0.004
Kořen 3, U_3	0.069	0.003

Levý soubor

Faktorová struktura v levém souboru.

První kanonický kořen $Kořen 1, U_1$ se vyznačuje vysokými vahami u znaků spokojenosti $Hoby1, Hoby2$.

U spokojenosti doma v rodině $Doma1, Doma2, Doma3$ jsou váhy mnohem nižší.

Významné kanonické korelace mezi znaky v obou souborech založené na prvním kanonickém kořenu jsou asi výsledkem vztahu mezi znaky spokojenost v práci, spokojenost se zálibami a koníčky a ostatní spokojeností v životě.

Když budeme uvažovat spokojenost v práci jako nezávisle proměnnou, můžeme říci, že spokojenost v práci ovlivňuje spokojenost v zálibách a koníčcích ale mnohem méně spokojenost doma v rodině.

Zátěže čili korelace s kanonickou proměnnou U			
	Kořen 1, U_1	Kořen 2, U_2	Kořen 3, U_3
<i>Hoby1</i>	0.824	-0.100	0.055
<i>Hoby2</i>	0.809	0.278	-0.150
<i>Doma1</i>	0.187	-0.017	0.237
<i>Doma2</i>	0.238	0.253	0.456
<i>Doma3</i>	0.278	0.414	0.173
<i>Ruzne1</i>	0.861	0.049	0.328
<i>Ruzne2</i>	0.821	0.245	0.241

6. Kanonické skóre: Kanonické proměnné U a V představují vážené součty znaků v každém souboru, $U_1 = a_1 y_1 + a_2 y_2 + \dots + a_q y_q$ a $V_1 = b_1 x_1 + b_2 x_2 + \dots + b_p x_p$

Váhy a_1, a_2, a_3 , a b_1, b_2, b_3 , zobrazené v tabulce kanonických vah odpovídají standardizovaným (Z-transformace) znakům v obou souborech.

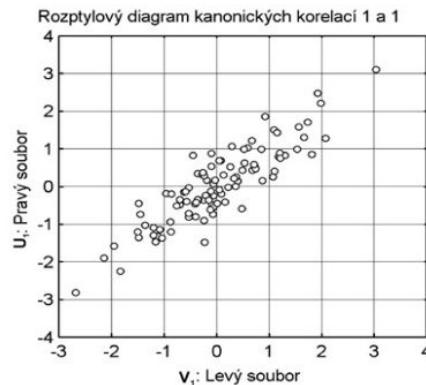
Užijeme tyto váhy k výpočtu skórů pro kanonické proměnné.

Váhy znaků a_1, a_2, a_3 k výpočtu skórů u kanonické proměnné U			
	Kořen 1, U_1	Kořen 2, U_2	Kořen 3, U_3
<i>Hoby1</i>	0.250	-1.636	-1.291
<i>Hoby2</i>	0.222	1.005	-1.096
<i>Doma1</i>	-0.156	-0.434	0.310
<i>Doma2</i>	-0.448	0.326	0.457
<i>Doma3</i>	-0.066	0.700	-0.317
<i>Ruzne1</i>	0.616	-0.361	1.737
<i>Ruzne2</i>	0.291	0.798	0.458

Váhy znaků b_1, b_2, b_3 k výpočtu skórů u kanonické proměnné V			
	Kořen 1, V_1	Kořen 2, V_2	Kořen 3, V_3
<i>Prace1</i>	0.217	-1.359	0.244
<i>Prace2</i>	0.592	0.371	-1.388
<i>Prace3</i>	0.300	0.832	1.289

7. Grafy kanonických skóre: Zobrazíme kanonické skóre znaků na pravé straně čili V proti skórum znaků na levé straně čili U a nenacházíme žádné vybočující objekty a ani rezidua po regresi neindikují nelineární trendy.

Objekty leží na přímce a nikoliv na křivce tvaru písmen S nebo U.



Rozptylový diagram kanonických korelací $V_1 = f(U_1)$ pro 10 znaků a 100 respondentů dat Spokojenost (STATISTICA).



Rozptylový diagram kanonických korelací $U_1 = f(V_2)$ pro 10 znaků a 100 respondentů dat Spokojenost (STATISTICA).

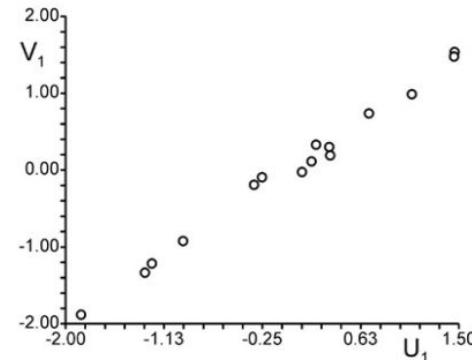
- Závěr:** spokojenost v práci významně ovlivňuje spokojenost při zábavě a i celkově.

Spokojenost doma v rodině se nejvíce příliš ovlivněna spokojeností v práci.

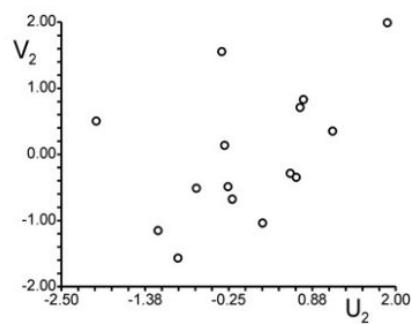
V praxi by měla být tato dotazníková úloha s různými skupinami respondentů opětovně vyhodnocena touto metodou.

Tím by se potvrdilo, zda kanonická faktorová struktura vede k věrohodné a spolehlivé interpretaci prvního kanonického kořene, tzv. *replikovatelnosti*.

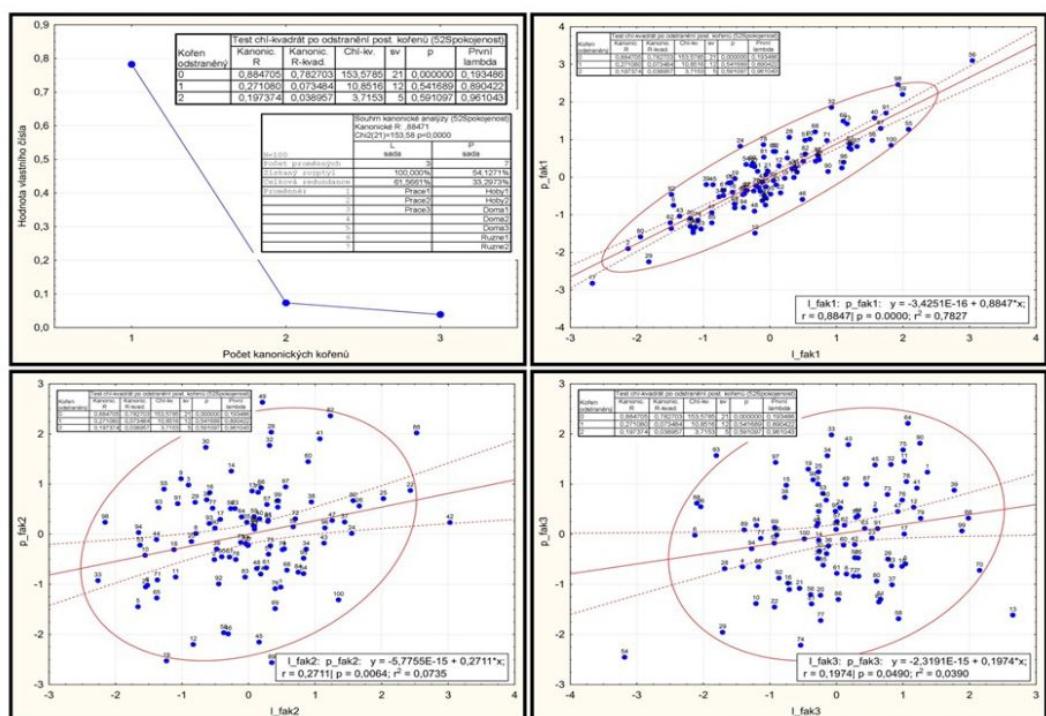
8. Vyšetření shluků objektů: je zde možnost indikovat shluky objektů na obrázku z programu NCSS2002.



Rozptylový diagram kanonických proměnných U_1 a V_1 pro 10 znaků a 100 respondentů dat Spokojenost (NCSS2002).



Rozptylový diagram kanonických proměnných U_2 a V_2 pro 10 znaků a 100 respondentů dat Spokojenost (NCSS2002).



Cvičení v programu STATISTICA

STATISTICA Cz - [Data: Factor.sta (10s krát 100r)]

	Zaměstnání 1	Zaměstnání 2	Zaměstnání 3	Hobby 1	Hobby 2	5	6	7	8	9	10	Různé 1	Různé 2	
1	105,126	101,659	115,06	100,998	95,184	101,667	85,553	104,036	110,278					
2	77,049	72,933	77,46	77,495	72,744	61,563	93,954	95,392	88,609	70,115	72,000			
3	86,017	82,206	78,88	86,017	82,206	78,889	77,951	86,773	108,070	93,348	86,021	70,688		
4	91,425	106,107	95,64	91,425	106,107	95,640	90,901	111,466	100,248	86,080	93,822	101,224	82,665	
5	113,714	92,029	99,07	113,714	92,029	99,079	79,277	98,416	104,013	83,271	69,621	82,820	70,022	
6	86,606	87,817	67,66	86,606	87,817	67,663	93,662	77,997	98,822	97,275	106,622	91,400	79,776	
7	95,067	94,505	98,08	95,067	94,505	98,081	95,243	97,613	97,261	95,243	95,243	95,243	95,243	
8	113,500	104,607	105,57	113,500	104,607	105,57	104,607	105,57	105,57	105,57	105,57	105,57	105,57	
9	104,549	97,299	94,07	104,549	97,299	94,074	88,636	98,112	97,705	99,595	99,761	99,399	105,906	
10	104,635	97,908	85,82	104,635	97,908	85,823	82,486	90,447	104,688	95,076	99,695	77,630	62,031	
11	102,064	87,010	94,66	102,064	87,010	94,667	79,203	68,492	78,995	86,430	78,922	89,729	87,553	
12	109,428	94,937	104,35	109,428	94,937	104,396	119,293	112,988	122,931	114,816	102,109	116,339	101,363	
13	89,994	77,392	100,77	89,994	77,392	100,771	97,026	111,107	107,660	116,858	114,730	88,715	76,495	
14	89,983	91,259	89,21	89,983	91,259	89,216	81,250	100,519	94,902	96,723	94,411	88,419	89,670	
15	96,946	103,043	97,493	96,946	103,043	97,493	96,815	96,833	92,778	110,072	96,162	102,368	105,517	
16	93,210	93,843	87,34	93,210	93,843	87,341	92,745	92,745	92,745	95,106	95,106	104,175	105,881	
17	70,905	65,903	74,25	70,905	65,903	74,251	70,905	70,905	70,905	70,905	70,905	70,905	70,905	
18	114,854	98,083	105,634	114,854	98,083	105,634	100,237	111,455	95,701	104,447	105,562	105,698	94,970	
19	100,315	92,518	87,609	100,315	92,518	87,609	103,273	88,362	105,023	102,772	116,442	96,448	91,195	
20	111,355	104,373	104,373	111,355	104,373	104,373	101,652	108,083	121,884	99,954	96,688	89,369	102,149	114,451
21	108,798	97,876	107,075	108,798	97,876	107,075	91,457	99,552	110,496	104,375	95,026	85,508	94,533	91,802
22	74,723	105,615	102,246	74,723	105,615	102,246	90,169	93,522	86,003	94,306	106,233	85,310	87,673	
23	93,878	98,987	95,486	93,878	98,987	95,486	88,063	92,444	107,834	97,738	105,225	87,353	89,168	
24	77,936	94,987	98,586	77,936	94,987	98,586	100,325	100,906	96,458	95,406	95,111	104,175	105,881	
25	92,676	97,267	97,267	92,676	97,267	97,267	97,267	97,267	97,267	97,267	97,267	97,267	97,267	
26	99,123	110,273	120,531	99,123	110,273	120,531	115,784	118,914	109,747	109,690	119,019	112,263	120,002	
27	92,469	94,971	94,383	92,469	94,971	94,383	94,371	94,371	94,371	94,371	94,371	91,297	92,224	
28	102,064	87,010	94,66	102,064	87,010	94,66	107,075	111,294	146,450	111,862	112,545	119,948	121,325	113,347
29	76,859	83,319	67,787	76,859	83,319	67,787	83,319	84,604	66,491	80,830	76,364	81,024	48,978	50,056
30	87,305	86,495	82,623	87,305	86,495	82,623	90,371	89,675	98,095	108,588	123,270	88,390	92,863	
31	90,115	98,804	93,923	90,115	98,804	93,923	102,658	117,803	113,116	100,333	106,156	100,138	99,204	
32	107,975	105,773	114,251	107,975	105,773	114,251	132,672	152,623	121,607	132,888	128,478	145,244	147,192	
33	118,087	96,954	93,445	118,087	96,954	93,445	96,845	74,378	95,036	104,447	105,562	105,698	94,970	
34	92,406	97,267	95,588	92,406	97,267	95,588	91,766	98,602	85,126	101,343	93,761	93,623	86,525	
35	121,235	114,295	113,363	121,235	114,295	113,363	118,700	122,608	112,363	110,938	123,047	117,641	123,765	
36	102,719	111,096	121,558	102,719	111,096	121,558	83,284	107,952	84,165	76,395	80,054	93,209	87,839	
37	91,074	105,772	105,772	91,074	105,772	105,772	103,061	123,072	116,930	112,745	106,480	113,189	105,560	
38	94,635	81,728	96,747	94,635	81,728	96,747	102,308	95,434	99,814	111,435	110,644	108,013	93,038	
39	114,468	115,632	115,656	114,468	115,632	115,656	121,383	127,679	106,550	113,191	111,581	127,931	128,899	
40	61,794	83,167	95,768	61,794	83,167	95,768	69,323	76,995	85,357	101,615	100,099	80,356	80,744	
41	69,571	99,519	107,377	69,571	99,519	107,377	100,471	109,374	100,876	105,846	105,623	100,425	99,226	

1. Zdrojová matica Factor.sta se načte z databáze EXAMPLES programu STATISTICA a obsahuje 100 řádků sledovaných případů respondentů a 10 sloupců faktorů a prediktorů.

STATISTICA Cz - [Data: Factor.sta (10s krát 100r)]

Kanonická analýza: Factor.sta

Základní nastavení

Proměnné: žádné

Vstupní soubor: Zdrojová data

Přehled popisných statistik a korelační maticy

OK

Zvolte proměnné pro kanonickou analýzu

1-Zaměstnání 1
2-Zaměstnání 2
3-Zaměstnání 3
4-Hobby 1
5-Hobby 2
6-Bydlení 1
7-Bydlení 2
8-Bydlení 3
9-Různé 1
10-Různé 2

OK

Pro zobrazení odpovídajících proměnných zvolte "Ukázat pouze...". Pro více informací stiskněte F1.

Vyberte proměnné:

1-10

Ukázat pouze odpovídající proměnné

OK

Storno

Možnosti

Otevři Data

SELECT CASES

CHD vynochána:

Celé případy

Nahrát průměrem

Vybrat vše Dl. názvy Detaily

2. Zavoláme Kanonickou analýzu z bloku Vícerozměrné techniky.

STATISTICA Cz - [Data: Factor.sta (10s krát 100r)]

1	105,126	101,659	115,06
2	77,049	72,933	77,46
3	86,017	82,206	78,88
4	91,425	106,107	95,64
5	113,714	92,029	99,07
6	86,606	87,817	67,66
7	95,067	94,505	98,08
8	113,500	104,607	105,57
9	104,549	97,299	94,07
10	104,635	97,908	85,82
11	102,064	87,010	94,66
12	109,428	94,937	104,35
13	89,994	77,392	100,77
14	89,983	91,259	89,21
15	96,946	103,043	97,493
16	93,210	93,843	87,34
17	70,905	65,903	74,25
18	114,854	98,083	105,634
19	100,315	92,518	87,609
20	111,355	104,373	104,373
21	108,798	97,876	107,075
22	74,723	105,615	104,35
23	93,878	90,580	94,987
24	77,936	94,987	88,34
25	77,515	100,672	102,301
26	99,123	110,273	120,531
27	92,469	94,971	94,383
28	102,064	87,010	101,190
29	76,859	83,319	67,787

3. Kliknutím na Proměnné se otevře okno Zvolte proměnné pro kanonickou analýzu, které naplníme 10 znaky a klikneme OK.

82,486	90,447	104,688	95,076	99,695	77,630	62,031
79,203	68,482	78,995	86,430	78,822	89,729	87,553
119,293	112,988	122,931	114,816	102,109	116,339	101,363
97,026	111,107	107,660	110,820	114,720	99,715	78,402
81,250	100,519	96,833	98,515	96,833	98,515	98,515
104,256	115,323	107,660	110,820	114,720	99,715	78,402
60,108	47,088	50,050	50,050	50,050	50,050	50,050
90,237	101,011	101,011	101,011	101,011	101,011	101,011
103,273	88,647	88,647	88,647	88,647	88,647	88,647
108,083	121,884	121,884	121,884	121,884	121,884	121,884
99,552	110,486	110,486	110,486	110,486	110,486	110,486
90,169	93,522	93,522	93,522	93,522	93,522	93,522
86,063	92,444	92,444	92,444	92,444	92,444	92,444
100,325	100,906	100,906	100,906	100,906	100,906	100,906
99,828	106,570	106,570	106,570	106,570	106,570	106,570
115,784	118,914	118,914	118,914	118,914	118,914	118,914
101,190	95,078	95,078	95,078	95,078	95,078	95,078
111,294	146,450	146,450	146,450	146,450	146,450	146,450
54,604	66,491	66,491	66,491	66,491	66,491	66,491
90,371	89,675	89,675	89,675	89,675	89,675	89,675

4. Záložku *Přehled popisných statistik a korelační maticy zaškrtneme a OK.*

517	b7,bb3	93,bb2	77,997	99,822	97,725	108,622	91,400	79,776
505	98,081	94,513	97,422	93,694	99,181	96,398	90,732	86,707
507	105,572	101,008	102,275	87,427	96,664	86,577	93,057	112,702
299	94,074	88,538	98,112	97,785	99,585	99,761	99,399	105,908
308	85,823	82,486	90,447	104,688	95,076	99,695	77,630	62,031
310	94,687	79,203	68,482	78,995	86,430	78,822	89,729	87,553
337	104,396	119,293	112,988	122,931	114,816	102,109	116,339	101,363
392	100,771	97,026	111,107	107,660	116,858	114,720	88,715	76,495
259	89,216	81,250	100,515	101,011	101,011	101,011	101,011	101,011
143	97,493	98,515	96,833	98,515	98,515	98,515	98,515	98,515
343	87,345	104,256	115,323	102,246	90,169	93,522	102,246	102,246
303	74,231	60,108	47,088	74,231	74,231	74,231	74,231	74,231
383	105,634	90,237	101,011	105,634	105,634	105,634	105,634	105,634
518	87,609	103,273	88,647	87,609	87,609	87,609	87,609	87,609
373	101,852	108,083	121,884	101,852	101,852	101,852	101,852	101,852
376	91,457	99,552	110,486	91,457	91,457	91,457	91,457	91,457
315	102,246	90,169	93,522	102,246	102,246	102,246	102,246	102,246
580	95,486	86,063	92,444	95,486	95,486	95,486	95,486	95,486
387	98,586	100,325	100,906	98,586	98,586	98,586	98,586	98,586
572	102,301	99,828	106,570	102,301	102,301	102,301	102,301	102,301
273	120,531	115,784	118,914	120,531	120,531	120,531	120,531	120,531
371	94,383	101,190	95,078	94,383	94,383	94,383	94,383	94,383
375	94,019	111,294	146,450	94,019	94,019	94,019	94,019	94,019
319	67,787	54,604	66,491	67,787	67,787	67,787	67,787	67,787

ChD vynechána párově
100 příp. zvoleny, 0 s chybějíc. daty
100 platné příp. akcept.
Zákl. výsledky Detaily Matice
Průměry & sm. odchyly Korelace
OK Storno Možnosti

STATISTICA Cz - [PS 1* - Průměry a směrodatné odchyly (Factor.sta)]						
Soubor	Úpravy	Zobrazit	Vložit	Formát	Statistika	Grafy
Nástroje	Data	Pracovní sešit	Okno	Nápověda		
Arial	10	B	I	U		
PS 1*						
	Průměry a směrodatné odchyly (Factor.sta)					
proměnná	Průměry Sm.odch.					
Zaměstnání 1	97,0296	15,52089				
Zaměstnání 2	98,1689	11,26746				
Zaměstnání 3	98,9430	12,48538				
Hobby 1	98,0252	15,93673				
Hobby 2	100,1081	19,94109				
Bydlení 1	99,5083	11,97813				
Bydlení 2	101,6029	11,06155				
Bydlení 3	101,3717	12,73475				
Různé 1	99,1629	16,96749				
Různé 2	98,2238	19,11151				

6. Okno dialogu *Popisných statistik a korelace* začíná tabulkou *Průměry a směrodatné odchyly* všech 10 znaků.

STATISTICA Cz - [PS 1* - Korelace (Factor.sta)]									
Soubor	Úpravy	Zobrazit	Vložit	Formát	Statistika	Grafy	Nástroje	Data	Pracovní sešit
Okno	Nápověda								
Arial	10	B	I	U					
PS 1*									
	Dialog popisných statistik								
proměnná	Zaměstnání 1	Zaměstnání 2	Zaměstnání 3	Hobby 1	Hobby 2	Bydlení 1	Bydlení 2	Bydlení 3	Různé 1
Zaměstnání 1	1,000	0,647	0,653	0,598	0,521	0,143	0,145	0,138	0,611
Zaměstnání 2	0,547	1,000	0,732	0,689	0,698	0,143	0,182	0,236	0,709
Zaměstnání 3	0,653	0,732	1,000	0,637	0,630	0,164	0,238	0,255	0,698
Hobby 1	0,598	0,689	0,637	1,000	0,805	0,536	0,634	0,583	0,904
Hobby 2	0,521	0,698	0,630	0,805	1,000	0,506	0,496	0,482	0,843
Bydlení 1	0,143	0,143	0,164	0,536	0,506	1,000	0,658	0,590	0,498
Bydlení 2	0,145	0,182	0,238	0,634	0,496	0,658	1,000	0,731	0,644
Bydlení 3	0,138	0,236	0,255	0,583	0,482	0,590	0,731	1,000	0,586
Různé 1	0,611	0,709	0,698	0,904	0,811	0,498	0,644	0,586	1,000
Různé 2	0,549	0,685	0,671	0,843	0,756	0,425	0,593	0,518	0,841

7. Kanonická korelace je založena na korelační matici znaků. Prvním krokem proto bude vyčíslení *Korelační matice*, pokud ovšem korelační matice nebyla načtena ve vstupních datech jako jedna možnost inputu. Všimněte si, že později budete zadávat proměnné pro dva výběry z těchto znaků, které jsme zde specifikovali.



Kovariance (Factor.sta)										
proměnná	Zaměstnání 1	Zaměstnání 2	Zaměstnání 3	Hobby 1	Hobby 2	Bydlení 1	Bydlení 2	Bydlení 3	Různé 1	Různé 2
Zaměstnání 1	240,896	113,218	126,467	147,947	161,282	26,551	24,918	27,235	160,998	162,832
Zaměstnání 2	113,218	126,956	102,961	123,640	156,781	19,349	22,665	33,860	135,476	147,462
Zaměstnání 3	126,467	102,961	155,885	126,737	156,860	24,471	32,911	40,488	147,846	160,023
Hobby 1	147,947	123,640	126,737	253,979	255,728	102,391	111,819	118,288	244,574	256,818
Hobby 2	161,282	156,781	156,860	255,728	397,847	120,840	109,388	122,491	274,404	288,026
Bydlení 1	26,551	19,349	24,471	102,391	120,840	143,476	87,149	90,002	101,298	97,226
Bydlení 2	24,918	22,665	32,911	111,819	109,388	87,149	122,358	102,923	120,802	125,446
Bydlení 3	27,235	33,860	40,488	118,288	122,491	90,002	102,923	162,174	126,592	126,010
Různé 1	160,998	135,476	147,846	244,574	274,404	101,298	120,802	126,592	267,896	272,852
Různé 2	162,832	147,462	160,023	256,818	288,026	97,226	125,446	126,010	272,852	365,250

ice (Factor.s rý graf	Zaměstnání 1	240,896	113,218	126,467	147,947	161,282	26,551	24,918	27,235	160,998	162,832
Zaměstnání 2	113,218	126,956	102,961	123,640	156,781	19,349	22,665	33,860	135,476	147,462	
Zaměstnání 3	126,467	102,961	155,885	126,737	156,860	24,471	32,911	40,488	147,846	160,023	
Hobby 1	147,947	123,640	126,737	253,979	255,728	102,391	111,819	118,288	244,574	256,818	
Hobby 2	161,282	156,781	156,860	255,728	397,847	120,840	109,388	122,491	274,404	288,026	
Bydlení 1	26,551	19,349	24,471	102,391	120,840	143,476	87,149	90,002	101,298	97,226	
Bydlení 2	24,918	22,665	32,911	111,819	109,388	87,149	122,358	102,923	120,802	125,446	
Bydlení 3	27,235	33,860	40,488	118,288	122,491	90,002	102,923	162,174	126,592	126,010	
Různé 1	160,998	135,476	147,846	244,574	274,404	101,298	120,802	126,592	267,896	272,852	
Různé 2	162,832	147,462	160,023	256,818	288,026	97,226	125,446	126,010	272,852	365,250	

Přehled popisných statistik: Factor.sta

ChC vyneschána párově

100 přip. zvoleny, 0 s chybějící daty

100 platné přip. akcept.

Zákl. výsledky Detaily Matice

Průměry & sm. odchylky Krabicový graf proměnných

Koeflace Maticový graf korelací

Kovariance SO=Součet čtverců/N

OK Storno Možnosti

Vyberte proměnné na krabicový graf

OK Storno

1-Zaměstnání 1
2-Zaměstnání 2
3-Zaměstnání 3
4-Hobby 1
5-Hobby 2
6-Bydlení 1
7-Bydlení 2
8-Bydlení 3
9-Různé 1
10-Různé 2

Vybrat vše DL názvy Detaily

✓ Ukázat pouze odpovídající proměnné

Hobby 2	161,282	156,781	156,860	255,728	397,647	120,840	109,388	122,491	274,404	288,0
Bydlení 1	26,551	19,349	24,471	102,391	120,840	143,476	87,149	90,002	101,298	97,2
Bydlení 2	24,918	22,665	32,911	111,819	109,388	87,149	122,358	102,923	120,802	125,4
Bydlení 3	27,235	33,860	40,488	118,288	122,491	90,002	102,923	162,174	126,592	126,0
Různé 1	160,998	135,476	147,846	244,574	274,404	101,298	120,802	126,592	267,896	272,8
Různé 2	162,832	147,462	160,023	256,818	288,026	97,226	125,446	126,010	272,852	365,2

Přehled popisných statistik: Factor.sta

ChC vyneschána párově

100 přip. zvoleny, 0 s chybějící daty

100 platné přip. akcept.

Zákl. výsledky Detaily Matice

Průměry & sm. odchylky Krabicový graf proměnných

Koeflace Maticový graf korelací

Kovariance SO=Součet čtverců/N

OK Storno Možnosti

Typ krabicového grafu:

Median/Kvartily/Rozpětí

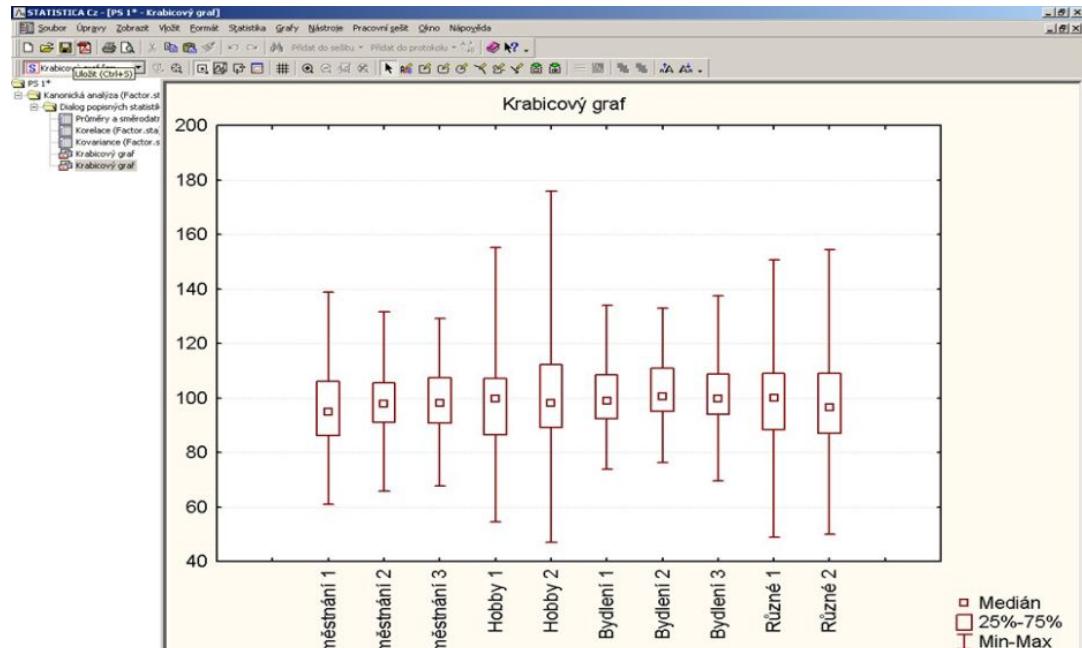
Průmér/SmCh/SmOdch

Průmér/SmOdch/1.96*SmOdch

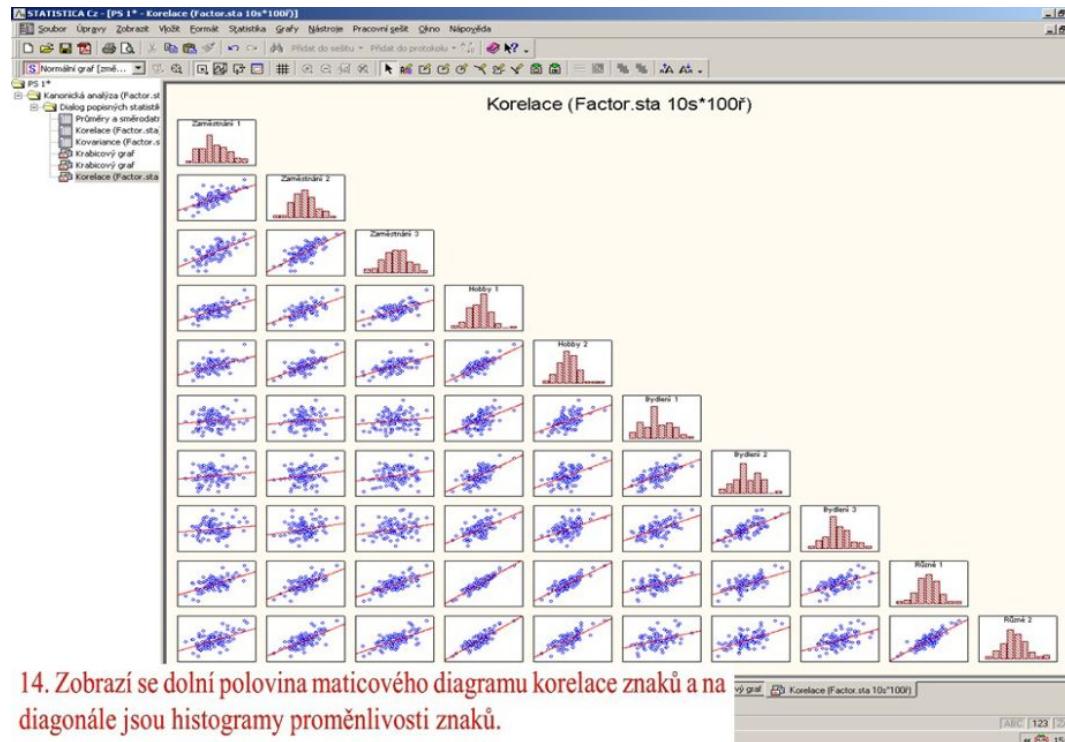
Průmér/SmCh/1.96*SmCh

Ostatní typy krabicových grafů a grafů odlehčených a extrémních hodnot najdete v nabídce Grafy.

10. Otevře se okno Typ krabicového grafu, ve kterém zaškrtneme jeden ze čtyř nabídnutých typů krabice.



11. Otevře se krabicový graf zadaných znaků. Všimneme si měř polohy, rozptýlení a tvaru. Vně vousů jsou indikovány vybočující body.



14. Zobrazí se dolní polovina maticového diagramu korelace znaků a na diagonále jsou histogramy proměnlivosti znaků.

Factor.sta										
	1	2	3	4	5	6	7	8	9	10
Zaměstnání 1	1,00000	0,64740	0,65262	0,59812	0,52110	0,14282	0,14514	0,13779	0,61135	0,54894
Zaměstnání 2	0,64740	1,00000	0,73189	0,68655	0,69778	0,14337	0,18185	0,23598	0,70863	0,68479
Zaměstnání 3	0,65262	0,73189	1,00000	0,63695	0,63003	0,16363	0,23830	0,25465	0,69789	0,67063
Hobby 1	0,59812	0,68655	0,63695	1,00000	0,80469	0,53638	0,63431	0,58284	0,90447	0,84320
Hobby 2	0,52110	0,69778	0,63003	0,80469	1,00000	0,50591	0,49691	0,48235	0,81101	0,76577
Bydlení 1	0,14282	0,14337	0,16363	0,53638	0,50591	1,00000	0,65774	0,59003	0,49842	0,42471
Bydlení 2	0,14514	0,18185	0,23830	0,63431	0,49591	0,65774	1,00000	0,73065	0,64364	0,59340
Bydlení 3	0,13779	0,23598	0,25465	0,58284	0,48235	0,59003	0,73065	1,00000	0,58587	0,51775
Různé 1	0,61135	0,70863	0,69789	0,90447	0,81101	0,49842	0,64364	0,58587	1,00000	0,84142
Různé 2	0,54894	0,68479	0,67063	0,84320	0,75577	0,42471	0,59340	0,51775	0,84142	1,00000
Průměry	97,02958	98,16886	98,94298	98,02522	100,10813	99,50832	101,60288	101,37174	99,16294	98,22383
Sm. odch.	15,52089	11,26746	12,48536	15,93673	19,94109	11,97813	11,06155	12,73475	16,96749	19,11151
Poč. příp.	100,00000									
Matice	1,00000									

16. Korelační matice znaků obsahuje Pearsonovy korelační koeficienty dvojic znaků a na diagonále jedničky. Matice je čtvercová a symetrická podle diagonály. Lze ji v této formě i uložit a použít jinde jako vstupní data k další statistické analýze některých vícerozměrných metod (např. MDS).

Hobby 2	U,52110	U,69789 / 8	U,63003	U,80469	1,00000	U,50591	U,49591	U,48235	U,811
Bydlení 1	0,14282	0,14337	0,16363	0,53638	0,50591	1,00000	0,65774	0,59003	0,49842
Bydlení 2	0,14514	0,18185	0,23830	0,63431	0,49691	0,64364	1,00000	0,73065	0,64364
Bydlení 3	0,13779	0,23598	0,25465	0,58284	0,48235	0,59003	0,73065	1,00000	0,58587
Různé 1	0,61135	0,70863	0,69789	0,90447	0,81101	0,49842	0,64364	0,58587	1,00000
Různé 2	0,54894	0,68479	0,67063	0,84320	0,75577	0,42471	0,59340	0,51775	0,84142
Průměry	97,02958	98,16886	98,94298	98,02522	100,10813	99,50832	101,60288	101,37174	99,16294
Sm. odch.	15,52089	11,26746	12,48536	15,93673	19,94109	11,97813	11,06155	12,73475	16,96749
Poč. příp.	100,00000								

Přehled popisných statistik: Factor.sta

ChD vynechána párově
100 přip. zvoleny, 0 s chybějíc. daty
100 platné přip. akcept.

Zákl. výsledky | Detaily | Matice |

Matice

OK | Storno | Možnosti ▾

15. Okno Přehled popisných statistik přináší v záložce Matice v číselné podobě korelační matici.

,23598	0,25465	0,58284	0,48235	0,59003	0,73065	1,00000	0,58587	0,51775	
,70863	0,69789	0,90447	0,81101	0,49842	0,64364	0,58587	1,00000	0,84142	
,68479	0,67063	0,84320	0,75577	0,42471	0,59340	0,51775	0,84142	1,00000	
,16886	98,94298	98,02522	100,10813	99,50832	101,60288	101,37174	99,16294	98,22383	
,26746	12,48538	15,93673	19,94109	11,97813	11,06155	12,73475	16,96749	19,11151	

Definice modelu: Factor.sta

Základní nastavení | Popisné statistiky |

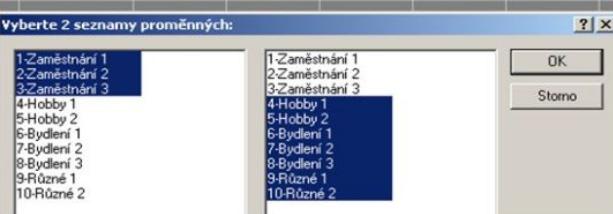
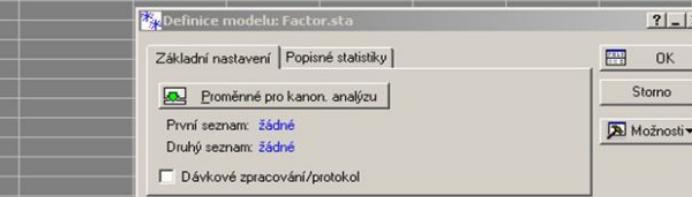
Proměnné pro kanon. analýzu

První seznam: žádné
Druhý seznam: žádné

Dávkové zpracování/protokol

OK | Storno | Možnosti ▾

17. Kliknutím na OK Přehledu popisných statistik se otevře okno Definice modelu se dvěma záložkami: Základní nastavení a Popisné statistiky. Otevřeme okénko Proměnné pro kanonickou analýzu a zadáme znaky do prvního a druhého seznamu proměnných.



18. V otevřeném okně *Vyberte 2 seznamy proměnných* jde totiž o levý výběr proměnných (*První seznam proměnných*) a pak o pravý výběr proměnných (*Druhý seznam proměnných*). Zdá se výhodnější rozlišovat slova *levý* a *pravý* než *první* a *druhý*. Do levého seznamu zadáme první tři znaky a do pravého seznamu pak zbývajících sedm znaků. Samozřejmě zadání můžeme i obrátit záměnou levého seznamu za pravý.

19. Protože jsme v *definici modelu* zaškrtili návěští *Dávkové zpracování/protokol*, udělal se nyní bleskově protokol 8 tabulek výsledků analýz CCA, které si nyní podrobně prohlédneme a interpretujeme.

Souhrn kanonické analýzy (Factor.sta)	
Kanonické R: .88471	
Chi2(21)=153,58 p=0,00000	
N=100	
Počet proměnných	sada
Získaný rozptyl	100,000% 54,1271%
Celková redundancy	61,5661% 33,2973%
Proměnné:	1 Zaměstnání 1 Hobby 1 2 Zaměstnání 2 Hobby 2 3 Zaměstnání 3 Bydlení 1 4 Bydlení 2 5 Bydlení 3 6 Různé 1 7 Různé 2

20. *Souhrn kanonické analýzy*: obsahuje celkové kanonické $R = 0.88471$, a tím vysokou statistickou významnost této korelace, protože $p = 0.0000$ je menší než zadaná hladina významnosti 0.05. Toto R lze vysvětlit jako jednoduchou korelací mezi váženou sumou skóre v každém souboru s vahami odpovídajícími prvnímu a nejdůležitějšímu kanonickému kořeni.

Test chi-kvadrát po odstranění post. kořenů (Factor.sta)	
Kořen odstraněný	
0	Kanonick. R, Chi-kv. sv, p, První lambda
0	0,884705, 0,782703, 153,5785, 21, 0,000000, 0,193486
1	0,271080, 0,073484, 10,8516, 12, 0,541689, 0,890422
2	0,197374, 0,038957, 3,7153, 5, 0,591097, 0,961043

21. *Test Chi2 po odstranění postupných kořenů*: testuje se statistická významnost všech tří kanonických kořenů.

STATISTICA Cz - [PS 1* - Struktura faktorů, L sada (Factor.sta)]

Soubor Úpravy Zobrazit Vložit Formát Statistika Grafy Nástroje Data Pracovní geští Okno Nápověda

Přidat do sešitu Přidat do protokolu Proměnné

Arial 10 B I U

PS 1*

- Kanonická analýza (Factor.sta)
 - Dialog popisných statistik kanonických korelacek
 - Průměry a směrodatné odchyly (Factor.sta)
 - Korelace (Factor.sta)
 - Kovariance (Factor.sta)
 - Krabicový graf
 - Krabicový graf
 - Korelace (Factor.sta 10s*100)
 - Dialog výsledků kanonických korelacek
 - Test chí-kvadrát po odstranění post. kořenů (F)
 - Kanonické váhy, levá sada (Factor.sta)
 - Kanonické váhy, pravá sada (Factor.sta)
 - Struktura faktorů, L sada (Factor.sta)
 - Získaný rozptyl (Proporce), levá sada (Factor.sta)
 - Struktura faktorů, P sada (Factor.sta)
 - Získaný rozptyl (Proporce), pravá sada (Factor.sta)
 - Vl. čísla (Factor.sta)
 - Souhrn kanonické analýzy (Factor.sta)
 - Vl. čísla (Factor.sta)

Proměnná	Struktura faktorů, L sada (Factor.sta)		
	Kořen 1	Kořen 2	Kořen 3
Zaměstnání 1	0,796461	-0,575348	0,186075
Zaměstnání 2	0,952643	0,100725	-0,286926
Zaměstnání 3	0,875390	0,217192	0,431880

22. Struktura faktorů, Levá sada: ukazuje jak korelují kanonické kořeny se znaky levé sady. Tyto korelace se nazývají **strukturní koeficienty**. Pouze první kanonický kořen vykazuje významnou korelací se znaky čili vysoké strukturní koeficienty.

STATISTICA Cz - [PS 1* - Získaný rozptyl (Proporce), levá sada (Factor.sta)]

Soubor Úpravy Zobrazit Vložit Formát Statistika Grafy Nástroje Data Pracovní geští Okno Nápověda

Přidat do sešitu Přidat do protokolu Proměnné

Arial 10 B I U

PS 1*

- Kanonická analýza (Factor.sta)
 - Dialog popisných statistik kanonických korelacek
 - Průměry a směrodatné odchyly (Factor.sta)
 - Korelace (Factor.sta)
 - Kovariance (Factor.sta)
 - Krabicový graf
 - Krabicový graf
 - Korelace (Factor.sta 10s*100)
 - Dialog výsledků kanonických korelacek
 - Test chí-kvadrát po odstranění post. kořenů (F)
 - Kanonické váhy, levá sada (Factor.sta)
 - Kanonické váhy, pravá sada (Factor.sta)
 - Struktura faktorů, L sada (Factor.sta)
 - Získaný rozptyl (Proporce), levá sada (Factor.sta)
 - Struktura faktorů, P sada (Factor.sta)
 - Získaný rozptyl (Proporce), pravá sada (Factor.sta)
 - Vl. čísla (Factor.sta)

Faktor	Získaný rozptyl (Proporce), levá sada (Factor.sta)	
	Získaný rozptyl	Reddnce.
Kořen 1	0,769395	0,602208
Kořen 2	0,129448	0,009512
Kořen 3	0,101157	0,003941

23. Získaný rozptyl (proporce), Levá sada: první kanonický kořen V_1 a U_1 vyčíslí 77% rozptylu tří znaků spokojenosti v zaměstnání. Znaky na levé straně vyčíslí okolo 60% rozptylu znaků spokojenosti v zaměstnání pomocí prvního kanonického kořene V_1 a U_1 čili **redundance**, což je tedy průměrné množství rozptylu vyčísleného pro každý znak prvním kanonickým kořenem.

R = 0,885 (vyjadřuje koreaci mezi U1 a V1), R-kvad = 0,783 (podíl rozptylu zahrnutého do kanonických proměnných)

Test chí-kvadrát po odstranění post. kořenů (Factor.sta)						
Kořen odstraněny	Kanon. R	Kanon. R-kvad	Chi-kv.	sv	p	První lambda
0	0,884705	0,782703	153,5785	21	0,000000	0,193486
1	0,271080	0,073484	10,8516	12	0,541688	0,890422
2	0,197374	0,038957	3,7153	5	0,591097	0,961043

Řádek pro první kanonický kořen.

Kanonické zátěže každého znaku vyjadřují koreaci mezi tímto znakem a dotyčnou kanonickou proměnnou:

Proměnná	Struktura faktorů, L sada (Factor.sta)		
	Kořen 1	Kořen 2	Kořen 3
Zaměstnání 1	0,796461	-0,575348	0,186075
Zaměstnání 2	0,952643	0,100725	-0,286926
Zaměstnání 3	0,875390	0,217192	0,431880

Průměr sumy $2,3074 : 3 = 0,7691$ čili **76,91%**
76,91% vyjadřuje průměrný podíl rozptylu vyčíslený ze 3 znaků, který je vysvětlen první kanonickou proměnnou

Získaný rozptyl (Proporcie)

Faktor	Získaný rozptyl	Reddnce.
Kořen 1	0,769395	0,602208
Kořen 2	0,129448	0,009512
Kořen 3	0,101157	0,003941

Redundanční index = $0,7691 \cdot 0,783 = 0,6022$ je mírou průměrného podílu rozptylu v pravé skupině znaků, který nebyl zahrnut do souboru znaků levé skupiny.

Celková redundance = celková korelace mezi znaky na pravé straně rovnice se vyčíslí: $0,602$ (od 1. kořene) + $0,010$ (od 2. kořene) + $0,004$ (od 3. kořene) = $0,616$ čili **61,6%** vystihuje značně silný vztah mezi třemi znaky souboru.

STATISTICA Cz - [PS 1* - Struktura faktorů, P sada (Factor.sta)]

Soubor Úpravy Zobrazit Vložit Formát Statistika Grafy Nástroje Data Pracovní geští Okno Nápověda

Přidat do sešitu Přidat do protokolu Proměnné

Arial 10 B I U

PS 1*

- Kanonická analýza (Factor.sta)
 - Dialog popisných statistik kanonických korelacek
 - Průměry a směrodatné odchyly (Factor.sta)
 - Korelace (Factor.sta)
 - Kovariance (Factor.sta)
 - Krabicový graf
 - Krabicový graf
 - Korelace (Factor.sta 10s*100)
 - Dialog výsledků kanonických korelacek
 - Test chí-kvadrát po odstranění post. kořenů (F)
 - Kanonické váhy, levá sada (Factor.sta)
 - Kanonické váhy, pravá sada (Factor.sta)
 - Struktura faktorů, L sada (Factor.sta)
 - Získaný rozptyl (Proporce), levá sada (Factor.sta)
 - Struktura faktorů, P sada (Factor.sta)
 - Získaný rozptyl (Proporce), pravá sada (Factor.sta)
 - Vl. čísla (Factor.sta)
 - Souhrn kanonické analýzy (Factor.sta)
 - Vl. čísla (Factor.sta)

Proměnná	Struktura faktorů, P sada (Factor.sta)		
	Kořen 1	Kořen 2	Kořen 3
Hobby 1	0,823914	-0,099577	0,055376
Hobby 2	0,808859	0,277944	-0,149747
Bydlení 1	0,186554	-0,017177	0,236525
Bydlení 2	0,238228	0,253169	0,456321
Bydlení 3	0,278220	0,414321	0,173396
Různé 1	0,861283	0,048749	0,328389
Různé 2	0,820765	0,245223	0,241010

24. Struktura faktorů, Pravá sada: ukazuje jak korelují kanonické kořeny se znaky pravé sady formou **strukturních koeficientů**. Nejvíce koreluje první kanonický kořen V_1 a U_1 se znaky Hobby1, Hobby2, Různé1 a Různé2. Zbylé dva kanonické kořeny korelují málo, statisticky nevýznamně.

STATISTICA Cz - [PS 1* - Získaný rozptyl (Proporce), pravá sada (Factor.sta)]

Získaný rozptyl (Proporce), pravá sada (Factor.sta)

Proměnná	Kořen 1	Kořen 2	Kořen 3
Získaný rozptyl	0,416787	0,326221	
Kořen 1	0,055104	0,004049	
Kořen 2	0,069379	0,002703	

25. **Získaný rozptyl (proporce), Pravá sada:** první kanonický kořen V_1 a U_1 vyčíslí 42% rozptylu znaků v pravé sadě a okolo 33% rozptylu znaků založených na V_1 a U_1 .

STATISTICA Cz - [PS 1* - Kanonické váhy, levá sada (Factor.sta)]

Proměnná	Kořen 1	Kořen 2	Kořen 3
Zaměstnání 1	0,217021	-1,35890	0,24350
Zaměstnání 2	0,592485	0,37139	-1,38769
Zaměstnání 3	0,300124	0,83222	1,28861

26. **Kanonické váhy u kanonického skóre, Levá sada:** Jde o váhy a_1, a_2, a_3 při výpočtu jednotlivých kanonických kořenů. Váhy odpovídají Z-standardizovaným hodnotám znaků v levé sadě. Tyto váhy se užijí k výpočtu kanonického skóre.

STATISTICA Cz - [PS 1* - Kanonické váhy, pravá sada (Factor.sta)]

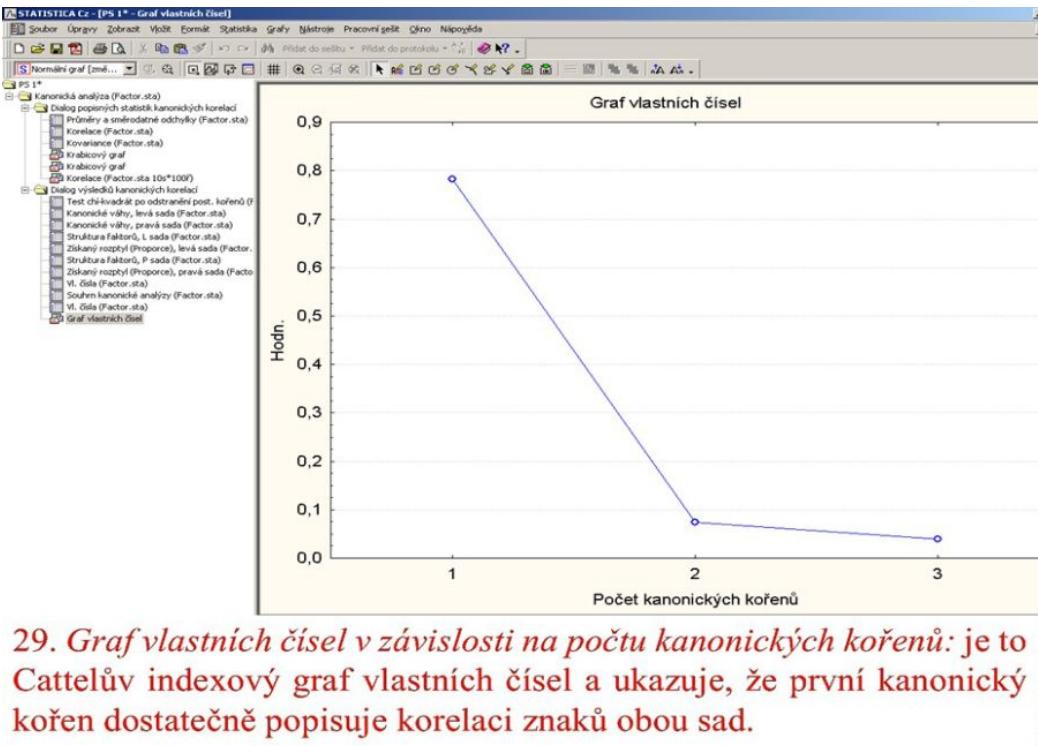
Proměnná	Hobby 1	Hobby 2	Bydlení 1	Bydlení 2	Bydlení 3	Různé 1	Různé 2
Kořen 1	0,249966	-1,63580	-1,29069				
Hobby 1	0,221850	1,00467	-1,09591				
Hobby 2	-0,156475	-0,43401	0,30966				
Bydlení 1	-0,447900	0,32580	0,45678				
Bydlení 2	-0,066126	0,69965	-0,31653				
Bydlení 3	0,615556	-0,36114	1,73651				
Různé 1	0,290859	0,79787	0,45774				

27. **Kanonické váhy u kanonického skóre, Pravá sada:** Jde o váhy b_1, b_2, b_3 při výpočtu jednotlivých kanonických kořenů. Váhy odpovídají Z-standardizovaným hodnotám znaků v pravé sadě. Tyto váhy se užijí k výpočtu kanonického skóre.

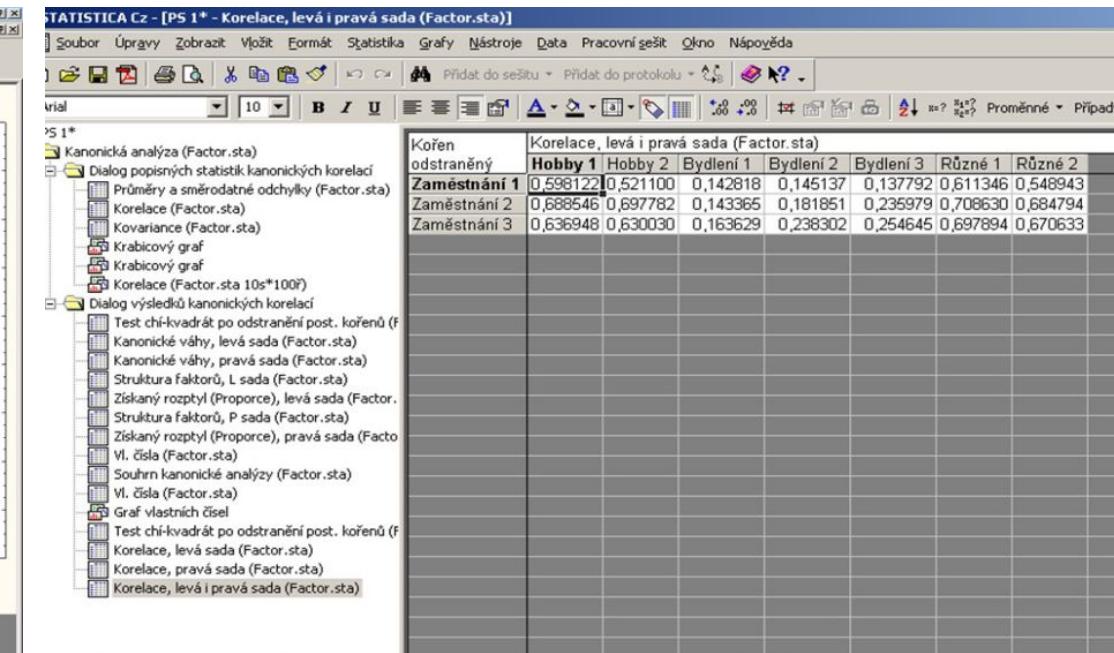
STATISTICA Cz - [PS 1* - Vl. čísla (Factor.sta)]

Vl. čísla (Factor.sta)	Kořen 1	Kořen 2	Kořen 3
Hodnota	0,782703	0,073484	0,038957

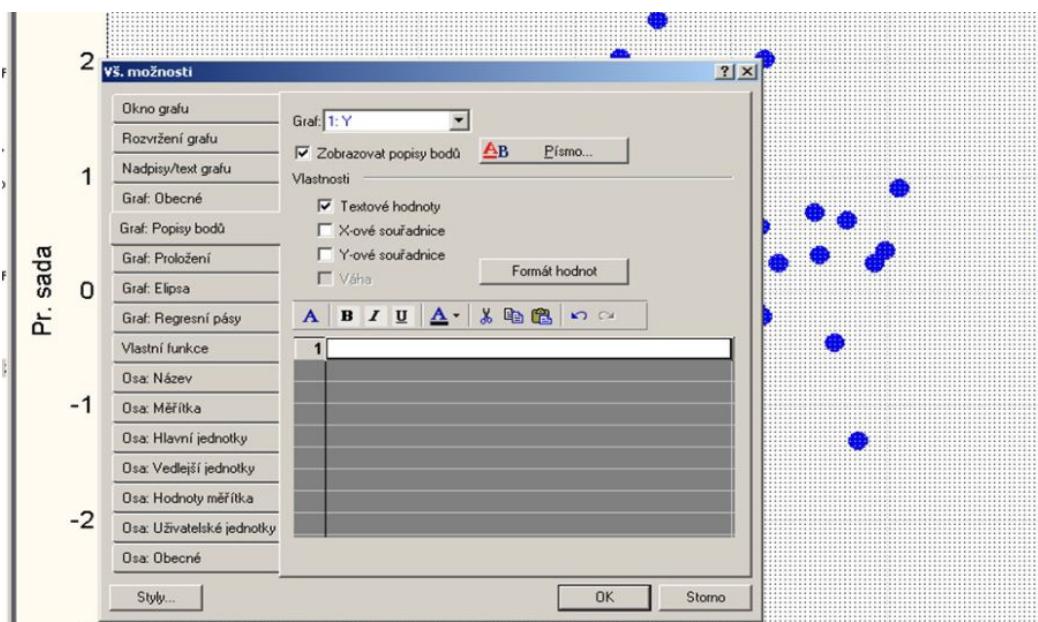
28. **Vlastní čísla u kanonických kořenů:** jsou vyčíslena vlastní čísla pro jednotlivé kanonické kořeny.



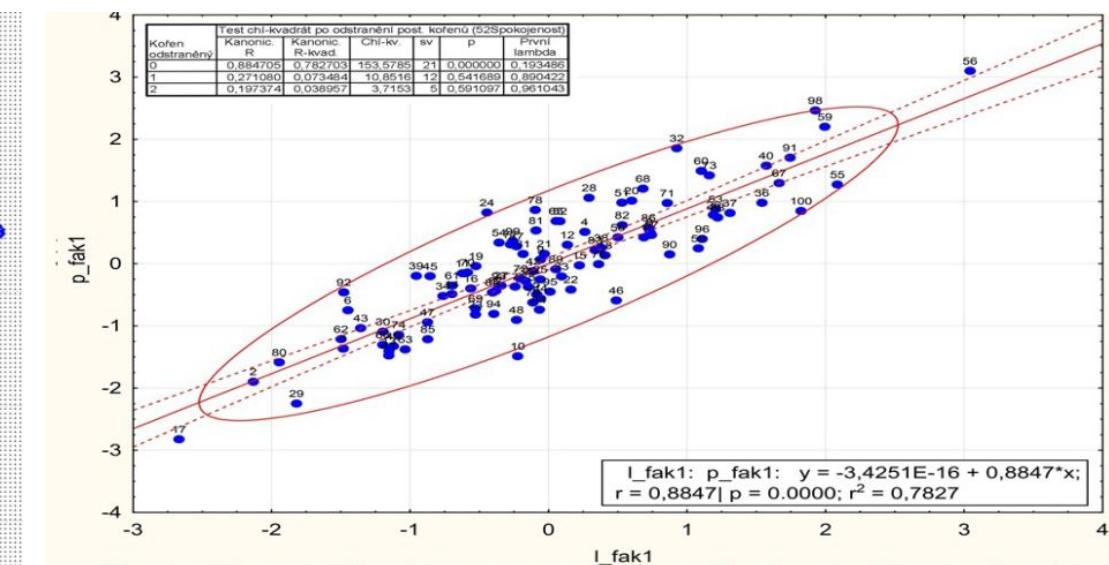
29. *Graf vlastních čísel v závislosti na počtu kanonických kořenů:* je to Cattelův indexový graf vlastních čísel a ukazuje, že první kanonický kořen dostatečně popisuje korelaci znaků obou sad.



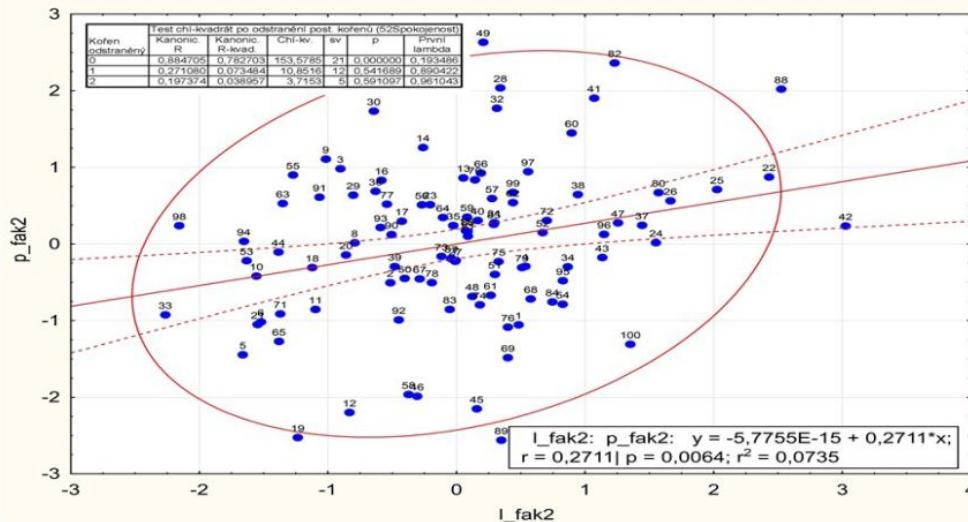
30. *Korelace levé a pravé sady znaků:* odkrývá korelační koeficienty mezi znaky levé a pravé sady.



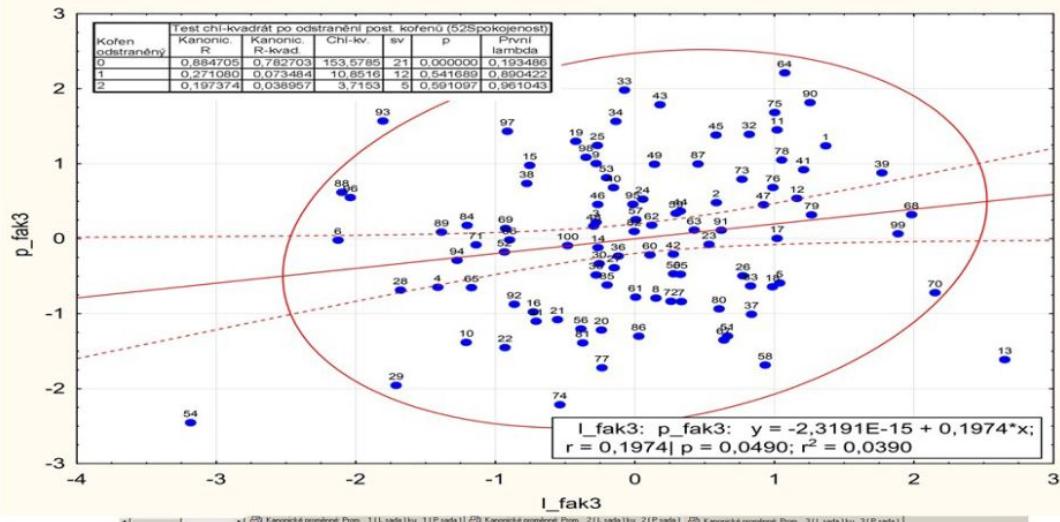
31. Nastavení popisu bodů v grafu kanonického skóre: nastavíme *Zobrazovat popisy bodů* v připravovaném grafu kanonického skóre.



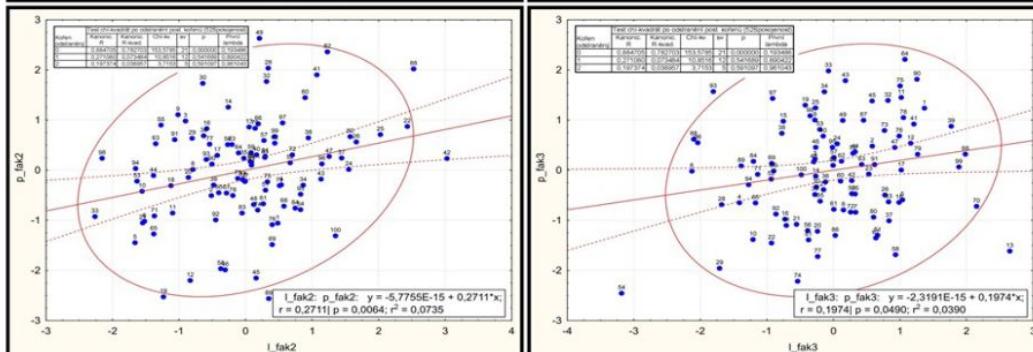
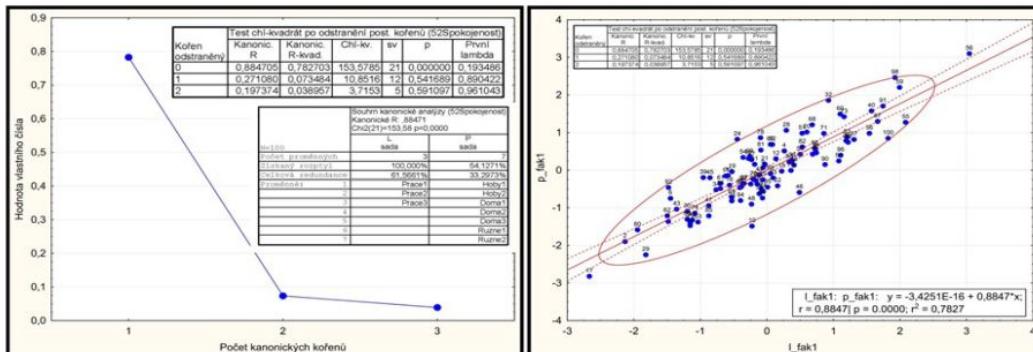
32. *Graf kanonického skóre respondentů pro Levá sada (1) proti Pravá sada(1):* ukazuje na lineární závislost (přímkovou) kanonického skóre pravé sady V_1 na kanonickém kořeni levé sady U_1 . V grafu lze indikovat vybočující body (respondenty), shluky respondentů a také nelinearitu grafu.



33. Graf kanonického skóre respondentů pro Levá sada (2) proti Pravá sada (2): dosahuje stejných závěrů jako u předešlého grafu. Ukazuje na ne tolik zřetelnou lineární závislost (přímkovou) kanonického skóre pravé sady V_2 na kanonickém kořeni levé sady U_2 . V grafu lze indikovat vybočující body (respondenty), shluky respondentů a také nelinearitu grafu.



33. Graf kanonického skóre respondentů pro Levá sada (3) proti Pravá sada (3): dosahuje stejných závěrů jako u předešlého grafu. Ukazuje na ne tolik zřetelnou lineární závislost (přímkovou) kanonického skóre pravé sady V_3 na kanonickém kořeni levé sady U_3 . V grafu lze indikovat vybočující body (respondenty), shluky respondentů a také nelinearitu grafu.



Přehled kanonické korelační analýzy

1. Cíle kanonické korelační analýzy

Data tvoří dvě skupiny znaků.

Každá skupina má jiný teoretický význam, jedna může být definovaná jako znaky nezávisle proměnné a druhá jako závisle proměnné.

CCA umožní řešení těchto úloh:

a) Rozhodnout, zda skupiny znaků, představujících obvykle rozličná měření na témaž předmětu, jsou nezávislé jedna na druhé, nebo naopak určit regresní vztah, který existuje mezi oběma skupinami.

b) Nalezení skupiny znaků, aby lineární kombinace každé skupiny byly maximálně korelovány.

c) Objasnění povahy kteréhokoliv ze vztahů, jež existují mezi skupinami znaků x a y , stanovením relativního příspěvku každého znaku do kanonické funkce.

2. Formulace úlohy kanonické korelační analýzy

Kritická je velikost výběru a dostatečný počet pozorování na jeden znak, a to alespoň 10 pozorování na 1 znak.

Láká zahrnovat hodně znaků, neuvažujíce důsledky malého výběru zakrytí smysluplného vztahu.

Malé výběry budou indikovat vždy statistickou významnost, protože bude nalezena dokonalá lineární kombinace díky malému počtu stupňů volnosti.

Klasifikace znaků na závislé a nezávislé je čistě formální a není vůbec důležitá.

Kanonická korelační analýza váží obě kanonické proměnné tak, aby maximalizovala korelací a nedává žádný zvláštní důraz na některou z kanonických proměnných.

Složení kanonické proměnné je důležité: musí existovat smysluplný základ původních znaků, ze kterých budou vytvářeny kanonické proměnné.

4. Nalezené řešení a dosažená těsnost proložení

Síla vztahu mezi páry kanonických proměnných je vyjádřena v kanonickém korelačním koeficientu.

Čtverec kanonických korelací představuje velikost sdíleného rozptylu mezi dvěma kanonickými proměnnými. Tyto čtverce nazývají **kanonické kořeny**.

Rutinou je analyzovat kanonické proměnné o statisticky významných korelačních koeficiencích.

Nevýznamné kanonické proměnné nemají vztahy mezi znaky vysvětleny.

Nestačí užití jednoduchého kritéria $H_0: \rho_i = 0$.

Jsou doporučována **tři kritéria rozhodování** vysvětlení kanonické proměnné:

- a) hladina významnosti,
- b) velikost kanonické korelace a
- c) míra redundancy.

3. Předpoklady kanonické korelační analýzy

Korelační koeficient má smysl, pokud mezi dvěma znaky existuje **lineární vztah**.

Při **nelineárním** je třeba vhodně transformovat.

CCA může být použita **pro metrické znaky** bez splnění předpokladu normality.

Normalita je požadována k provedení testů.

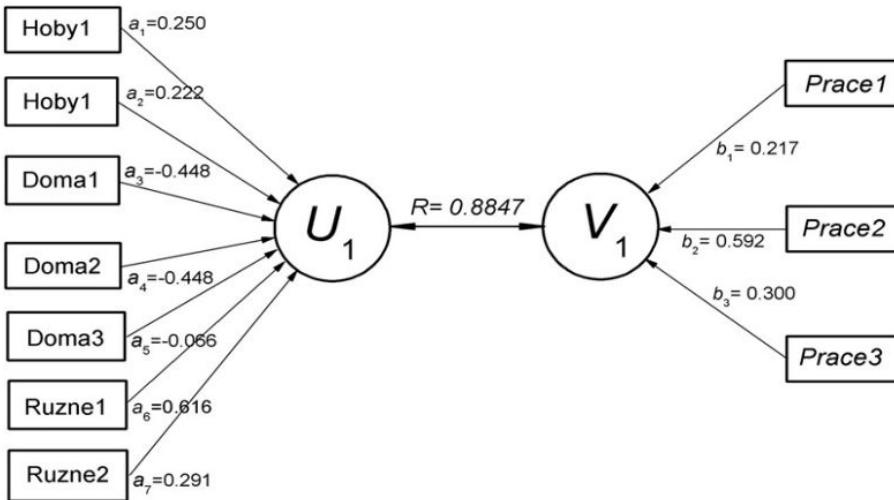
CCA může být použita i pro **nenormálně** rozdelené znaky.

Heteroskedasticita měla by být potlačena.

Hladina významnosti: vypočtená hladina významnosti P je uvažována za přijatelnou, pokud je rovna nebo menší než zvolená hodnota $\alpha = 0.05$, $P \leq \alpha$ pak je testovaný **korelační koeficient statisticky významný**.

Velikost kanonických korelací: by měla být vzata v úvahu, i když neexistuje obecný návod o vhodné velikosti kanonických korelací.

Míra redundancy sdíleného rozptylu: i když mírou redundancy je sdílený rozptyl, může vést tento ukazatel k chybným vysvětlením, protože čtverec kanonických korelací představuje rozptyl sdílený lineárními kombinacemi skupin znaků a ne rozptyl určený ze skupin znaků.



První pár kanonických korelačních proměnných U_1 a V_1 dostačně popisuje závislost 7 znaků $Hoby1, Hoby2, Doma1, Doma2, Ruzne1, Ruzne2$ na 3 znacích $Prace1, Prace2, Prace3$ zdrojové matice dat *Spokojenost* (STATISTICA, ORIGIN).

b) **Kanonické zátěže** také zvané **korelace kanonické struktury**, měří lineární korelaci mezi původním znakem a kanonickými proměnnými.

Vyjadřují **rozptyl**, který sdílejí původní znaky s kanonickými proměnnými.

Může být vysvětlen jako **faktorová zátěž** vyčíslená jako relativní příspěvek každé původní proměnné do každé kanonické funkce.

Každá kanonická proměnná se uvažuje **oddeleně** a vyčísluje se korelace skupin znaků včetně kanonické proměnné.

Také **kritéria k určování významnosti korelací kanonické struktury** jsou stejná jako u faktorových zátěží.

c) **Kanonické křížové zátěže:** týká se korelací každého znaku y se znaky x a opačně.

Konvenční zátěže **korelují** s původními znaky. Kanonické křížové zátěže vyjadřují lépe vztah mezi znaky x a y .

5. Interpretace výsledků

Vysvětlení kanonických proměnných a určení relativní důležitosti každého z původních znaků v kanonických proměnných třemi metodami:

a) **Kanonické váhy:** vysvětlení kanonických proměnných se týká vyšetření znaménka a velikosti **kanonické váhy** charakterizované pro každý znak v parametrech a, b .

Původní znaky s **velkými váhami** přispívají více do kanonických proměnných.

Podobně znaky s **vahami opačného znaménka** vykazují inverzní vztah s každým znakem.

Znaky s **vahami stejného znaménka** vykazují přímý vztah.

Malá váha může znamenat, nevýznamný znak v kanonické proměnné.

6. Ověření výsledků

CCA by měla ověřit, že výsledky nejsou pouze specifické pro daný výběr dat, ale že se dají zobecnit.

Postup: vytvoří se dva dílčí výběry dat a provede se analýza s každým výběrem odděleně.

Pak jsou porovnány kanonické funkce, zátěže kanonických proměnných atd.

Když je nalezen vysoký rozdíl, je třeba uvažovat o jiném způsobu vyšetřování dat.

Kanonická korelace pouze maximalizuje korelace, takže se kanonické váhy a zátěže podstatně změní, je-li jeden znak odebrán z kterékoliv kanonické proměnné.

7. Diagnostikování problémů kanonické korelační analýzy

CCA má tato **kritická úskalí**:

- a) Výběr dat by měl být reprezentativní a náhodný.
- b) Špatná spolehlivost měření může vést k nižším odhadům korelací mezi znaky.
- c) Mají se vyhledat odlehlé hodnoty pomocí rozptylových diagramů znaků.
- d) Když znaky přispívají pouze málo, jsou obvykle kandidáty na odstranění.
- e) Je třeba ověřit kanonickou korelaci vyšetřením koeficientů, zda kanonická korelace je dost vysoká.
- f) Liší-li se podstatně kanonické koeficienty od kanonických zátěží, tj. mají-li třeba rozdílné znaménko, pak je nutné je objasnit.
- g) Jelikož kanonická korelace užívá obou skupin znaků y a souboru x , je celkový počet znaků použitych velký, což může způsobit problém u úloh s dírami v datech.

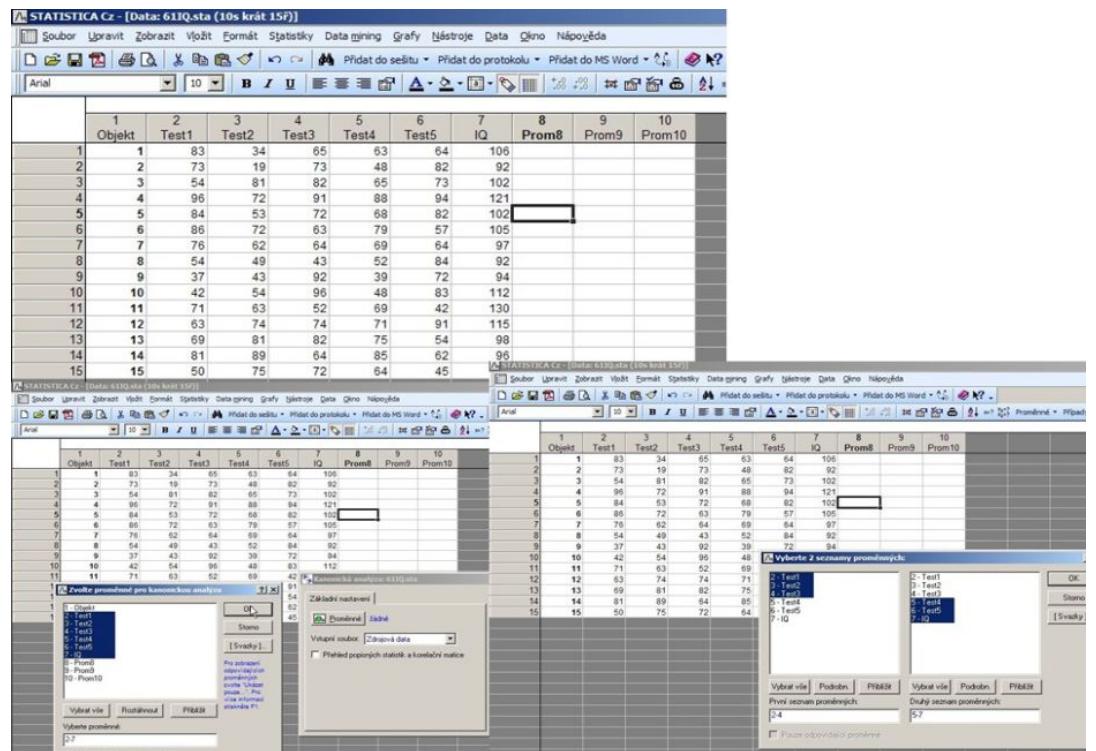
PŘÍKLAD 6.2 Testy IQ kanonickou korelační analýzou

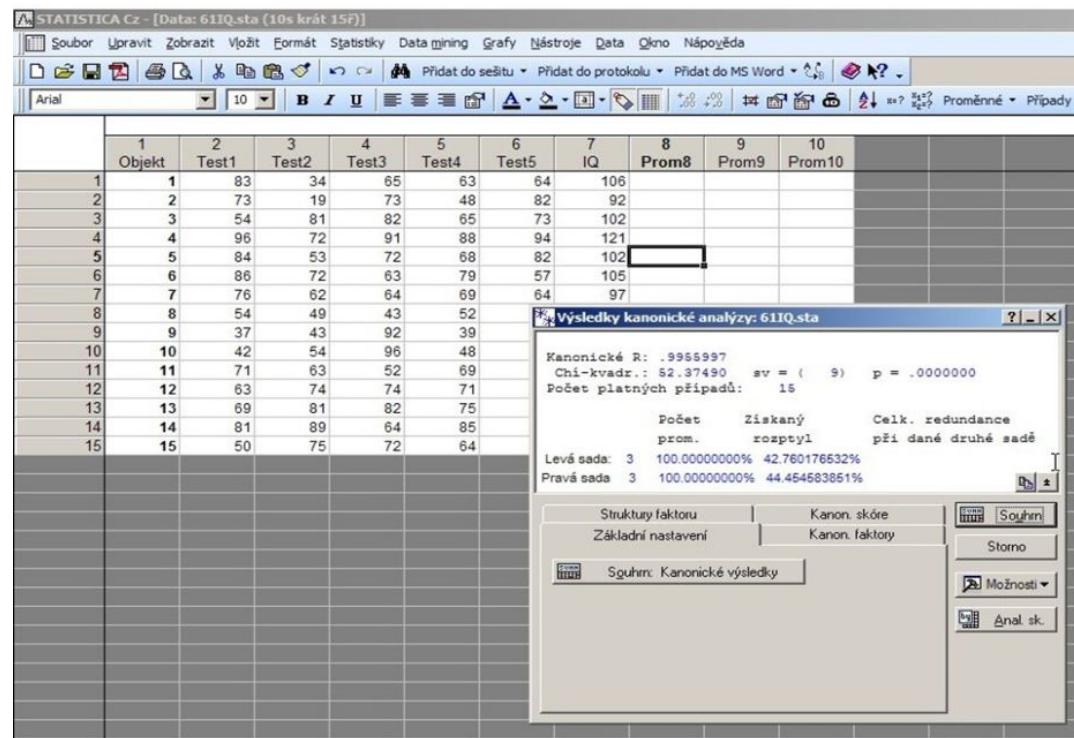
Bыло выштранено 15 respondentů pěti rozličnými testy a vyčíslena hodnota inteligenčního kvocientu IQ. Tím vzniklo dohromady šest znaků zdrojové maticy dat. Cílem je posoudit korelaci dvou skupin testů, když je k dispozici 15 dvojic vážených průměrů.

Úkol úlohy: vyšetřete skupinu 3 vybraných testů v závislosti na druhé skupině 3 testů a pokuste se popsat závislost ($TEST4, TEST5, IQ$) = $f(TEST1, TEST2, TEST3)$.

○ Data: Každý z pěti testů obsahoval 10 bodovaných otázek, hodnocených v rozsahu 0 až 100 bodů. Matice TEST1 až TEST5 a IQ představuje 15 hodnot váženého průměru z 10 odpovědí u každého testu.

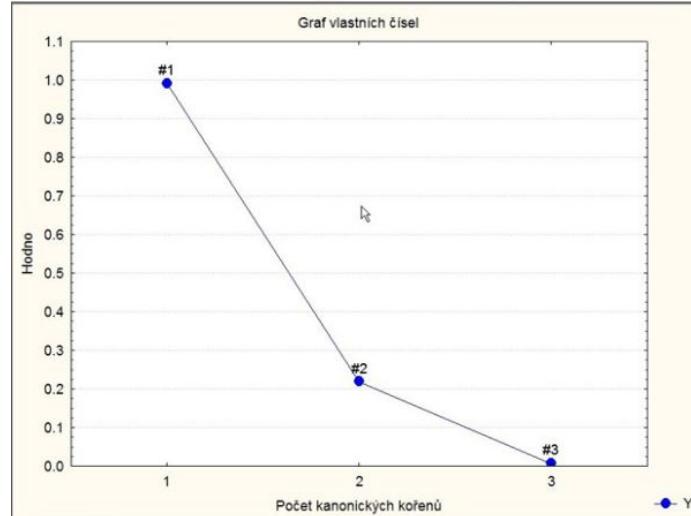
Objekt	Test1	Test2	Test3	Test4	Test5	IQ
1	83	34	65	63	64	106
2	73	19	73	48	82	92
3	54	81	82	65	73	102
4	96	72	91	88	94	121
5	84	53	72	68	82	102
6	86	72	63	79	57	105
7	76	62	64	69	64	97
8	54	49	43	52	64	92
9	9	37	43	92	39	72
10	10	42	54	96	48	83
11	11	71	63	52	69	42
12	12	63	74	74	71	91
13	13	69	81	82	75	54
14	14	81	89	64	85	62
15	50	75	72	64	45	96





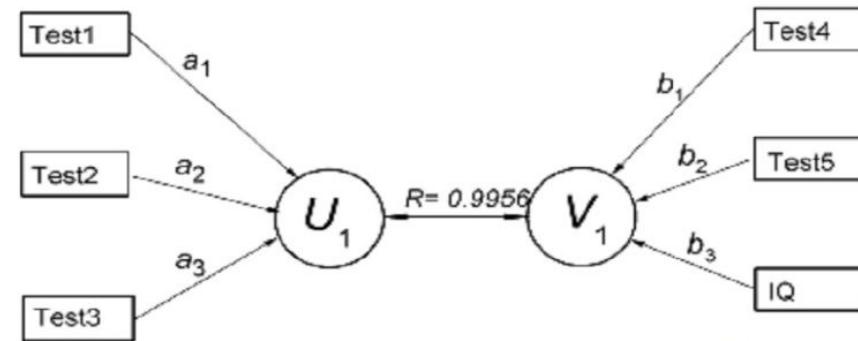
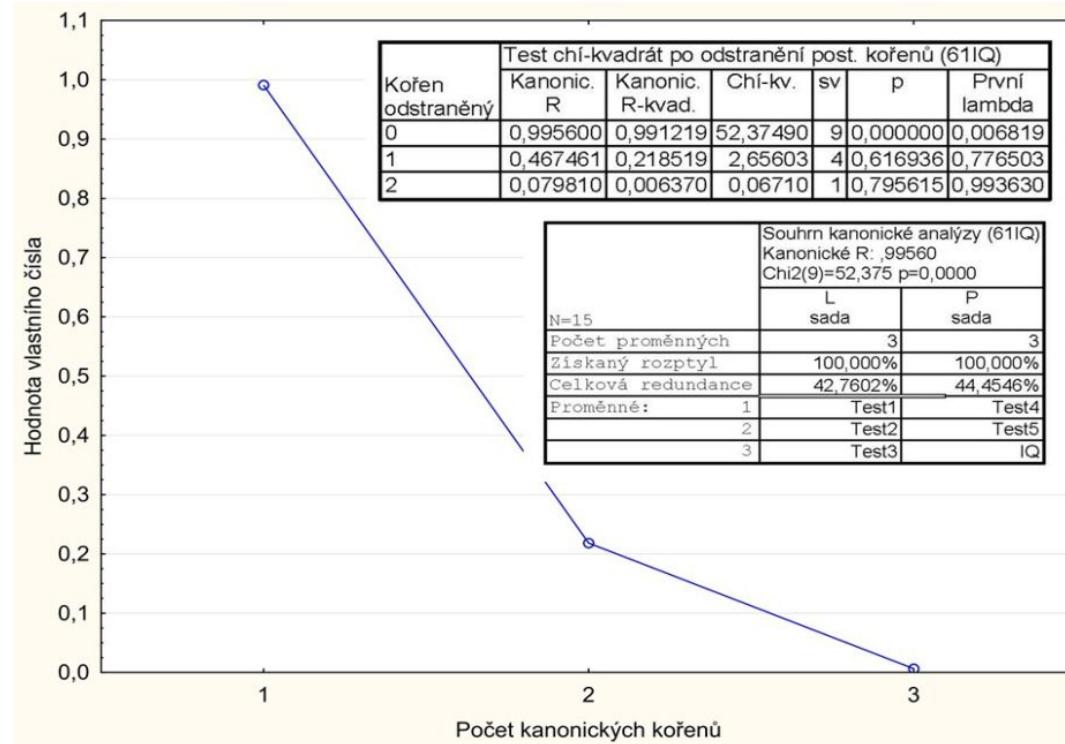
Kanonické váhy, pravá sada (61IQ.sta)

Proměnná	Kořen 1	Kořen 2	Kořen 3
Test4	-1.02137	-0.104989	0.37086
Test5	0.00599	-0.990267	0.22402
IQ	0.06536	-0.229775	-1.05024

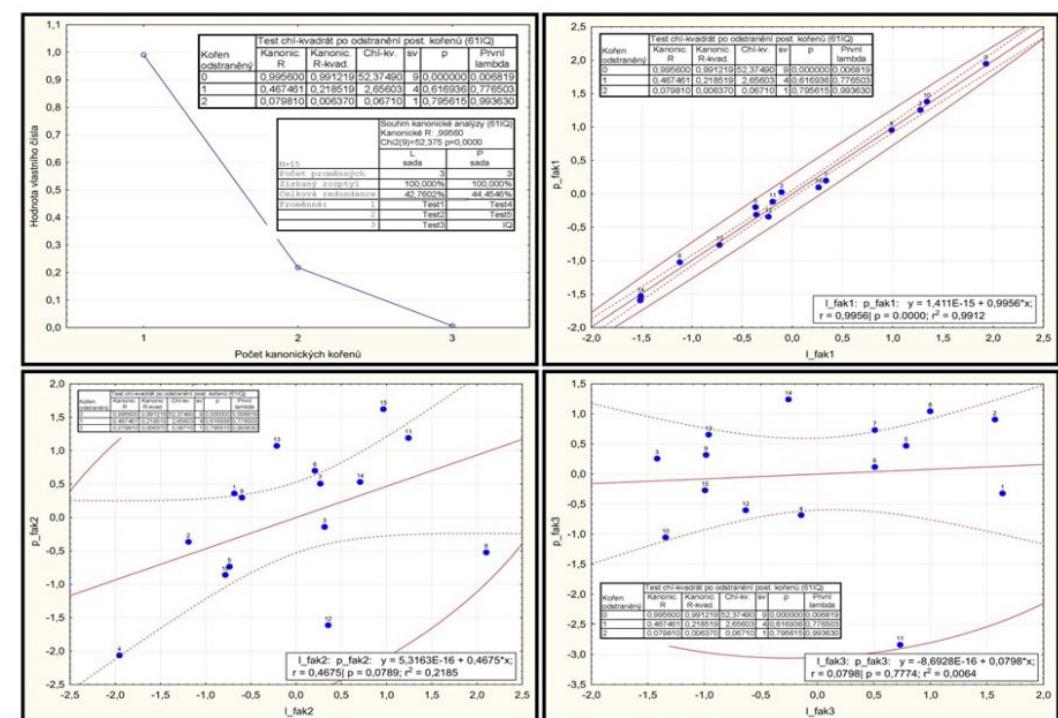
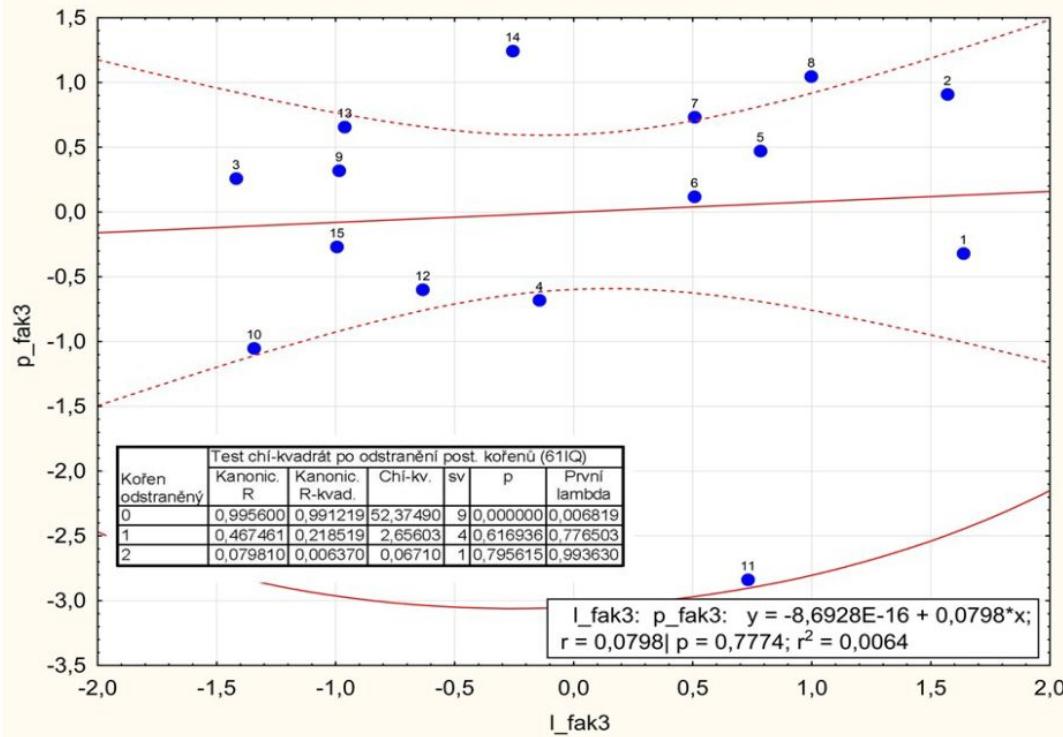
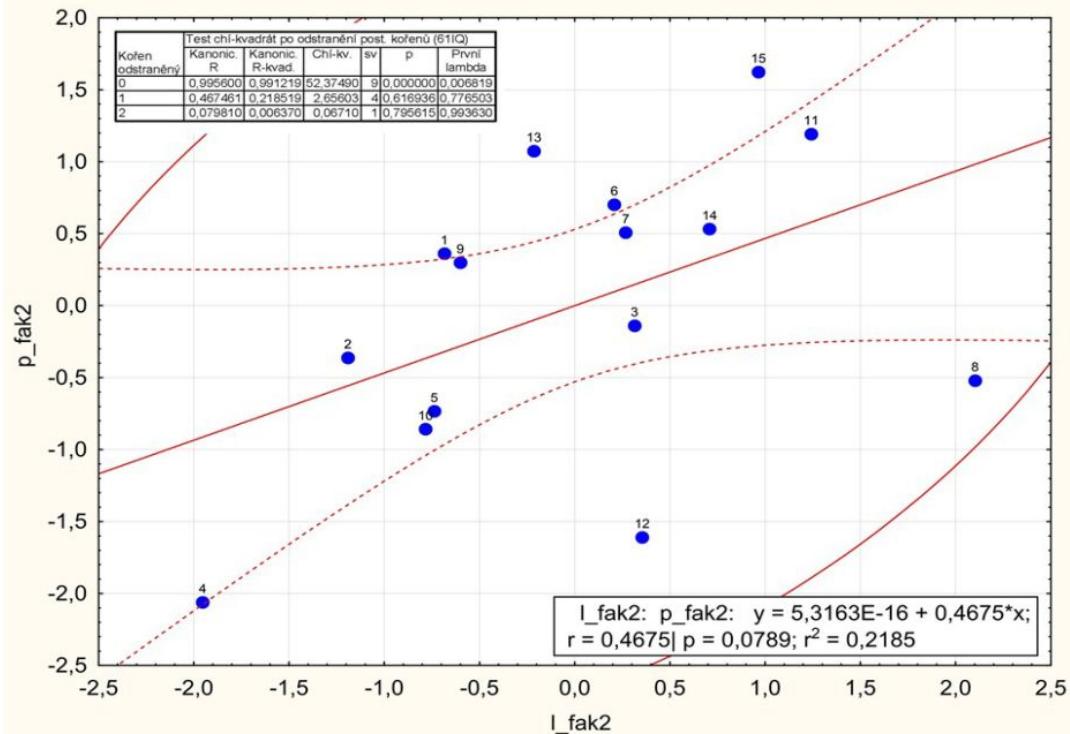
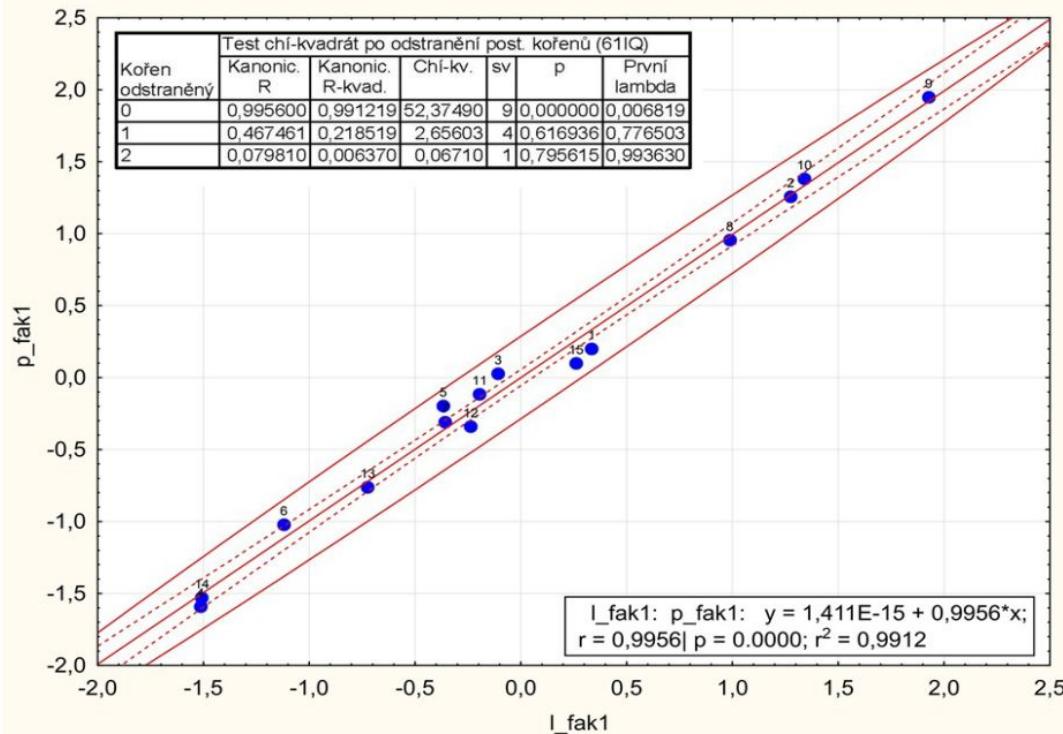


Souhrnné kanonické analýzy (61IQ.sta)

N=15	L	P
Počet proměnných	3	3
Ziskaný rozptyl	100.000%	100.000%
Celková redundance	42.7602%	44.4546%
Proměnné:	1 Test1 Test4 2 Test2 Test5 3 Test3 IQ	



Obr.-6.8b-První páár kanonických korelačních proměnných U_1 a V_1 dostatečně popisuje závislost 3 znaků $Test1, Test2, Test3$ na 3 znacích $Test4, Test5, IQ$ zdrojové matice dat IQ (STATISTICA, ORIGIN).



PŘÍKLAD 6.3 Ovlivnění subjektivních postoju a názoru žen svým zdravotním stavem

V roce 1975 bylo dotazníkem vyšetřeno v San Fernando Valley na předměstí Los Angeles 465 žen věku od 20 do 59 let. Průzkum byl zaměřen na zdravotní, demografické a subjektivně zbarvené postoje a stavy a odhalit míru znaků osobního postoje, vztaženého ke svým zdravotním charakteristikám.

Cíl úlohy: existují ve 9 znacích zdrojové matici dat nějaké skryté vztahy, a to mezi prvními 5 znaky zdravotního stavu ženy a následnými 4 jejími psychologickými znaky?

○ **Data:** Ve zdrojové matici dat Canon každá z žen odpovídala v dotazníku na 9 otázek.

V 1. souboru proměnné U jsou 4 znaky: **Postženy** značí míru důležitosti postavení ženy, **Domin** značí míru dominantního postavení v rodině, **Manžel** je hodnotící postoj ke svému manželství, **Sebehod** značí míru sebehodnocení. Větší čísla ukazují nepříznivější postoj, zvýšené pocity bezmocnosti ovlivnit něčí osud nebo narůstající nespokojenosť se svým manželstvím a stále větší sebepodeřování.

V 2. souboru proměnné V je 5 znaků zdravotního stavu: **Mental** se týká mentální zdraví, **Fyzické** se týká fyzického zdraví, **Lékař** vyjadřuje časté návštěvy u lékaře, **Léky** vyjadřuje oblibu v užívání léků, **Drogy** značí frekvenci užívání psychotropních léků. Vyšší hodnoty bodů vyjadřují horší mentální a fyzické zdraví, častější návštěvy lékaře a větší užívání léků. Znaky s kódem L ve zdrojové matici dat značí transformovaná data.

Objekt	Lékař	Léky	Fyzické	Mental	Sebehod	Domin	Manžel	Drogy	Postženy
1	1	8	5	8	16	5	36	3	42
2	3	7	4	6	17	5	21	0	38
..
465	3	8	5	2	16	6	19	4	45

Úloha B69 Účinnost vakcíny Biocan R po vakcinaci a revakcinaci

Ověřována imunogenita vakcíny u psů odpovědí po první vakcinaci a revakcinaci (IU v séru). Použito 40 psů věku od 3 do 6 měsíců, obou pohlaví a vakcinováno proti vzteklině 1 ml vakcíny Biocan R intramuskulárně. Odebrány vzorky krve na titr protilátek proti vzteklině stanoveném počtu mezinárodních jednotek (IU), a to v rozmezí 3, 6 a 12 měsíců po první vakcinaci.

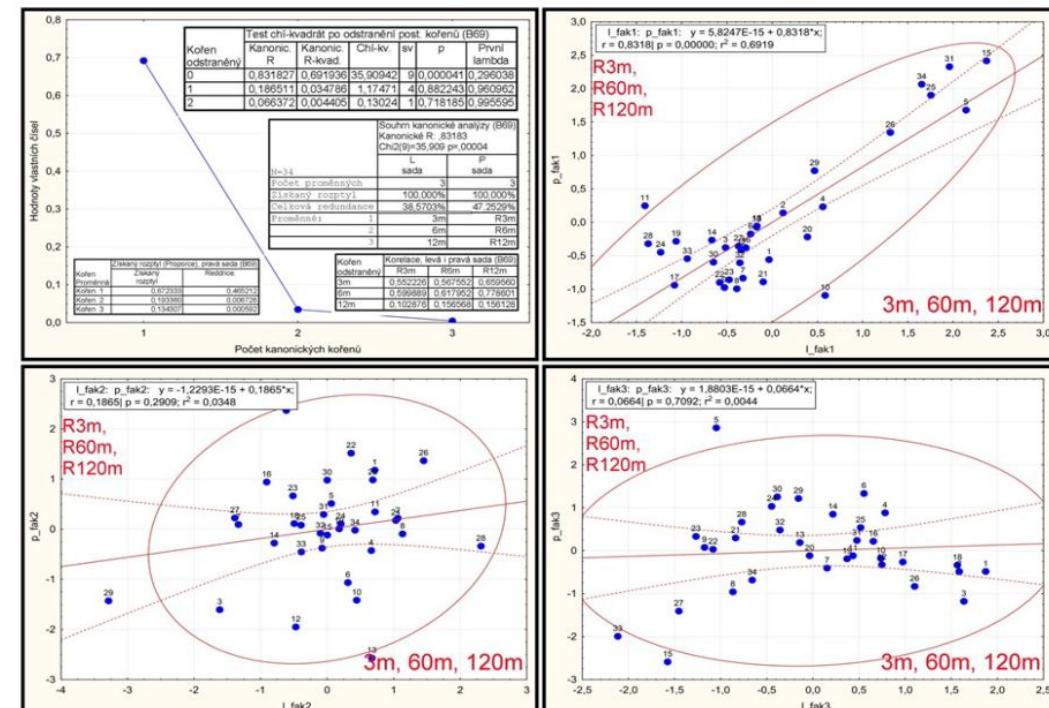
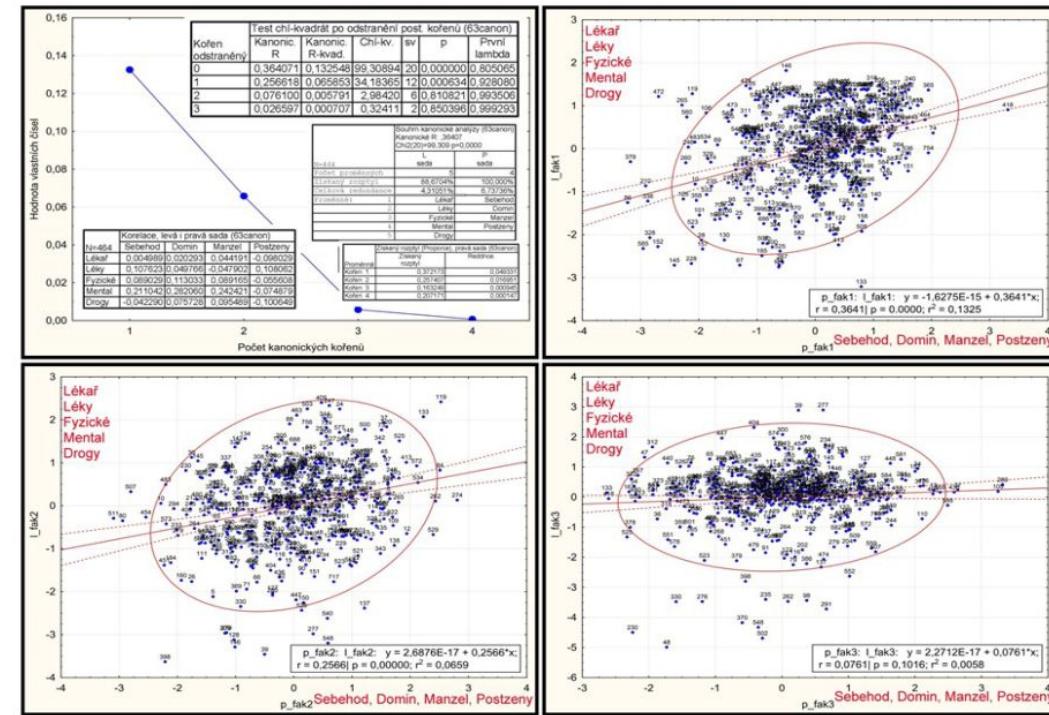
Za rok byli psi revakcinováni Biocanem R v dávce opět 1 ml a krev odebírána opět v intervalu 3, 6 a 12 měsíců.

Úkol úlohy: Existuje vazba mezi protektivní imunitou získanou po první vakcinaci a protektivní imunitou získanou po opakováné revakcinaci u stejněho druhu zvířat?

První vakcinace

3 měsíce	6 měsíců	12 měsíců	3 měsíce	6 měsíců	12 měsíců
4.3	4.1	1.95	9.1	8.1	5.3
.....
3.5	3.4	1.75	7.8	7.5	4.3

Revakcinace



Úloha B72 Kanonická korelační analýza vztahu mezi znaky mozku a tělesných proporcí

Willerman et al. (1991) shromáždil výběr 40 pravorukých studentů psychologie, (kde ID jsou Female nebo Male) a podrobil je čtyřem Wechslerovým subjektivním IQ-testům:

Subjektivně: Slovní zásoba dle **FSIQ** testu,

Podobnosti a Konstrukce bloků **VIQ**,

Kompletace obrázků **PIQ**)

Objektivně: použita metoda magneticko-rezonančního zobrazování 18 MRI záběrů:

MRIcount k určení velikosti mozků studentů v pixelech,

hmotnost studenta **Weight**,

výška studenta **Height** (inch),

pohlaví studenta **Gender**.

Úkol: Kanonickou korelační analýzou zjistěte, zdali jsou výsledky těchto testů závislé na velikosti mozků a tělesných proporcích respondentů.

○ Data: Zdrojová data:

ID	FSIQ	VIQ	PIQ	Weight	Height	MRIcoun	Gender
F01	133	132	124	118	64,5	816932	Female
....
M20	89	91	89	179	75,5	935863	Male

Úloha C34 Vyšetření vlivu zárodku na vlastnosti hydratovaného oxidu titančitého

Titanové roztoky rozkladem ilmenitu kyselinou sírovou vylučují za varu bílou sraženinu hydratovaného oxidu titančitého k přípravě pigmentového TiO₂. Operace této hydrolyzy je zároveň dělicím procesem, kdy se s vysokým výtěžkem získá TiO₂ v pevné fázi, zatímco železo a ostatní nečistoty zůstávají v roztoku. K dosažení dobrého výtěžku je nutná přítomnost zárodků dvěma metodami hydrolyzy:

zárodková a zřed'ovací.

Zárodková hydrolyza spočívá v přípravě zárodků mimo hydrolyzační kád' a přidání zárodku do roztoku na začátku hydrolyzy.

Cílem úlohy je nalézt **znaky** připravovaného zárodku, na kterých závisí **kvalita** připravené suspenze TiO₂. Nalezněte závislost mezi **znaky zárodku** a **kvalitou výsledného hydrolyzátu**?

○ Data: Popis znaků ve sloupcích:

Hydrolyzát (levá strana CCA): Sed je sedimentace, **D50** je velikost částic d 50,

Část. 1μ je obsah částic do 1 μm,

Zárodek (pravá strana CCA): Stab. je stabilita, **TiO2 ce** je obsah celkového TiO₂, **TiO2 ro** je obsah rozpustného TiO₂, **TiO2 ko** je obsah koloidního TiO₂, **Na** je obsah sodíkových iontů, **TiO2/Na** je poměr obsahu TiO₂ a sodíkových iontů.

i	Sed.	D50	Část.1μ	Stab.	TiO2 ce	TiO2 ro	TiO2 ko	Na	TiO2/Na
1	123,0	3,2	14,6	115,0	158,2	123,1	22,2	14,4	11,0
....
17	111,0	4,3	11,3	160,0	155,4	147,4	5,2	18,7	8,3

