

Statistické metody II, cvičení č. 9

Shluková analýza

(Cluster analysis)

Brno, 9.5.2016
Klára Ambrožová



Použitá data

- V této prezentaci budou použita jiná data, než se kterými budete pracovat na cvičení
- Analýza a interpretace dat bude stejná
- Jde o počet obyvatel daného kraje ČR k 31. 12. 2014
- K analýze dat je použit program STATISTICA – karta Statistiky – modul Vicerozměrné/průzkumné techniky – Shluková analýza

	Počet _obyv	PO _do14let	PO _15-64let	PO _nad65let
Hlavní město Praha	1	182	846	229
Středočeský kraj	1	220	874	219
Jihočeský kraj	637	96	425	114
Plzeňský kraj	575	85	384	105
Karlovarský kraj	299	44	202	52
Ústecký kraj	823	129	553	140
Liberecký kraj	438	68	292	77
Královéhradecký kraj	551	82	363	104
Pardubický kraj	516	78	344	93
Kraj Vysočina	509	76	340	92
Jihomoravský kraj	1	175	783	213
Olomoucký kraj	635	94	424	115
Zlínský kraj	585	84	393	107
Moravskoslezský kraj	1	179	824	213

Trocha teorie: Shluková analýza

- Metoda pro zhodnocení vícerozměrných dat
- Snaha o nalezení skupin, kde členové uvnitř skupiny si budou maximálně podobní, zatímco se budou maximálně lišit od členů ostatních skupin
- Existují metody hierarchické (vznikají shluky různých úrovní) a nehierarchické
- Pracujeme s pojmem „vzdálenost“ mezi objekty (často se používá euklidovská vzdálenost)



$$d_{ij} = \sqrt{(x_{1i} - x_{1j})^2 + (x_{2i} - x_{2j})^2}$$

Trocha teorie: Shluková analýza

- Předpoklady shlukové analýzy:
 - Nekorelovanost proměnných (lze zajistit použitím výsledků PCA namísto původních proměnných)
 - Nezávislost na jednotkách (nutná standardizace)
 - Stejný význam proměnných při shlukování (lze vyřešit přidáním váhových koeficientů do výpočtu vzdáleností)

Pozn. Ve cvičení se bude řešit druhý bod
→ prvním krokem je označení celé tabulky
a jít na kartu Data – Transformace –
Standardizace (resp. Data –
Standardizovat – Vše – OK)

The screenshot shows a Microsoft Excel spreadsheet titled 'PERSONAL\1jD\Statistika2\cv9\Pocet_ob_31_12_2014.xls : List1'. The data is organized into three columns: 'Pocet obyvatel' (Count of inhabitants), 'PO_15-64let' (Population aged 15-64), and 'PO_nad65let' (Population aged 65+). The data includes values for various regions: Liberecký kraj, Královéhradecký kraj, Pardubický kraj, Kraj Vysočina, Jihomoravský kraj, Olomoucký kraj, Zlínský kraj, and Moravskoslezský kraj.


A 'Standardizace hodnot' (Standardize values) dialog box is open over the spreadsheet. It contains the following settings:

- Proměnné: Vše (All variables)
- Případy: ALL (All cases)
- Váhy: Vypnuto (unchecked)
- Description: Hodnoty zvolených proměnných budou standardizovány (z proměnných). Nezvolené případy budou vyjmuty ze všech výpočtů.
- Buttons: OK and Storno (Cancel).

Interpretace výsledků

a) Hierarchické shlukování

- V tomto případě chceme shlukovat kraje, tzn. případy/řádky, a použijeme k tomu všechny proměnné




Budeme interpretovat následující tyto čtyři výstupy:
Dendogram, rozvrh
shlukování, graf rozvrhu
shlukování a matici
vzdáleností

Interpretace výsledků

a) Hierarchické shlukování - dendrogram


Na grafu vidíme, jak se postupně k sobě připojovaly jednotlivé kraje – čím více vpravo je kraj připojen, tím je méně podobný jádru objektů, které vzniklo jako první



Např. první byly spojeny kraje Jihočeský a Olomoucký a téměř ve stejné vzdálenosti i Pardubický a Vysočina. Naopak, jako úplně poslední byl k spodnímu velkému shluku připojen Ústecký kraj, je tedy velmi odlišný.

Interpretace výsledků

a) Hierarchické shlukování - dendrogram



Fakt, že tyto dva finální shluky se sloučily až ve vzdálenosti cca 3.4 poukazuje na to, že jsou skutečně velmi odlišné.

Před sloučením do finálního shluku nám zde vznikly dva velké shluky: v prvním je Praha, Jihomoravský kraj, Moravskoslezský kraj a Středočeský kraj, ve druhém shluku ostatní kraje. Tento shluk vzniknul ve vzdálenosti cca 1,2 (jde o bezrozměrné číslo).

Interpretace výsledků

a) Hierarchické shlukování – rozvrh shlukování

Zobrazuje téměř totéž jako předchozí graf: na ose y jsou tentokrát přesně číselně vzdálenosti, v nichž došlo ke spojení, na řádcích jsou pak shluky, přičemž poslední objekt na daném řádku byl připojen v tomto kroku.

Např. ve čtvrtém kroku (4. řádek) byl ke shluku Plzeňského a Zlínského kraje připojen Královéhradecký ve vzdálenosti 0, 137.

spojení vzdálen.	Rozvrh slučování (Pocet_ob_31_12_2014)								
	Jednoduché spojení								
	Euklid. vzdálenosti								
Obj. č. 1	Obj. č. 2	Obj. č. 3	Obj. č. 4	Obj. č. 5	Obj. č. 6	Obj. č. 7	Obj. č. 8	Obj. č. 9	Obj. 9
,0418297	Jihočeský kraj	Olomoucký kraj							
,0509008	Pardubický kraj	Kraj Vysočina							
,0653331	Plzeňský kraj	Zlínský kraj							
,1375565	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj						
,1936774	Jihomoravský kraj	Moravskoslezský kraj							
,2494285	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina				
,2925919	avní město Praha	Jihomoravský kraj	Moravskoslezský kraj						
,3199249	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina		
,4390908	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina	Liberecký kraj	
,7396800	avní město Praha	Jihomoravský kraj	Moravskoslezský kraj	Středočeský kraj					
,8789036	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina	Liberecký kraj	Karlova
1,145492	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina	Liberecký kraj	Karlova
3,408849	avní město Praha	Jihomoravský kraj	Moravskoslezský kraj	Středočeský kraj	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj

Interpretace výsledků

a) Hierarchické shlukování – rozvrh shlukování

Interpretace dendogramu a rozvrhu shlukování:

Je zjevné, že nejpodobnější jsou si kraje: Jihočeský a Olomoucký; Pardubický a Vysočina; Plzeňský a Zlínský; Jihomoravský a Moravskoslezský (vytvořily jádra shluků). Poslední uvedené jádro k sobě nakonec ještě přidalo Hl. město Prahu a Středočeský kraj, ostatní kraje vytvořily druhý shluk. Finální shluk (14. řádek) vznikl až ve vzdálenosti 3,4, což je rozdíl vůči přechozímu kroku o $3,4 - 1,14 = 2,26$, tyto dva shluky jsou tedy extrémně rozdílné.

spojení vzdálen.	Rozvrh slučování (Pocet_ob_31_12_2014)								
	Jednoduché spojení								
	Euklid. vzdáleností								
,0418297	Jihočeský kraj	Olomoucký kraj							
,0509008	Pardubický kraj	Kraj Vysočina							
,0653331	Plzeňský kraj	Zlínský kraj							
,1375565	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj						
,1936774	Jihomoravský kraj	Moravskoslezský kraj							
,2494285	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina				
,2925919	avní město Praha	Jihomoravský kraj	Moravskoslezský kraj						
,3199249	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina		
,4390908	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina	Liberecký kraj	
,7396800	avní město Praha	Jihomoravský kraj	Moravskoslezský kraj	Středočeský kraj					
,8789036	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina	Liberecký kraj	Karlovarský kraj
1,145492	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj	Pardubický kraj	Kraj Vysočina	Liberecký kraj	Karlovarský kraj
3,408849	avní město Praha	Jihomoravský kraj	Moravskoslezský kraj	Středočeský kraj	Jihočeský kraj	Olomoucký kraj	Plzeňský kraj	Zlínský kraj	Královéhradecký kraj

Interpretace výsledků


a) Hierarchické shlukování – graf rozvrhu shlukování

Graf rozvrhu shlukování má na ose x krok, v němž došlo k připojení a na ose y vzdálenost (podobně jako byla předtím na ose x u dendogramu).

Hledáme optimální počet shluků: nalezneme největší „schod“ v grafu.

Zde je schod zjevně na 13. kroku, tzn. 14. krok shlukování bychom již neměli provádět.
Tzn. ideální jsou v tomto případě **dva shluky**.

Někdy to však z grafu nebude 100 % jasné a bude třeba zjistit, kde došlo k maximální ztrátě informace, z rozvrhu shlukování.



Interpretace výsledků

a) Hierarchické shlukování – matice vzdáleností

Matice vzdáleností je čtvercová a určuje vzdálenost mezi objektem na řádku a ve sloupci. Tzn. na diagonále budou nuly (vzdálenost mezi Hlavním městem Prahou a Hlavním městem Prahou je přirozeně 0).

Např. vzdálenost mezi Středočeským krajem a Prahou je 0,739.

Tyto řádky nebudou v následujícím kroku potřeba a je třeba je **odstranit!**

	Pocet_ob_31_12_2014					
	1 Hlavní m	2 Středoče	3 Jihočesk	4 Plzeňský	5 Karlovar	6 Ústeck
Hlavní m	0,00000	0,73968	3,83818	3,97614	4,95833	3,6
Středoče	0,73968	0,00000	4,16506	4,32545	5,33496	3,8
Jihočesk	3,83818	4,16506	0,00000	0,38057	2,09765	1,1
Plzeňský	3,97614	4,32545	0,38057	0,00000	1,72079	1,5
Karlovar	4,95833	5,33496	2,09765	1,72079	0,00000	3,2
Ústecký	3,63727	3,87090	1,14549	1,52598	3,23584	0,0
Libereck	4,39730	4,75649	1,22098	0,84734	0,87890	2,3
Královéh	4,01630	4,37339	0,51129	0,13756	1,59842	1,6
Pardubic	4,13905	4,49343	0,73813	0,36294	1,35993	1,8
Kraj Vys	4,16467	4,52274	0,78601	0,40895	1,31224	1,9
Jihomora	0,40713	0,93480	3,52370	3,64147	4,57323	3,4
Olomouck	3,84344	4,17707	0,04183	0,36299	2,08318	1,1
Zlínský	3,96530	4,31877	0,34223	0,06533	1,76859	1,4
Moravsko	0,29259	0,80253	3,63758	3,76436	4,71406	3,4
Průměry	0,74593	0,91156	-0,04170	-0,23029	-1,08678	0,5
Sm.Odch.	1,43456	1,55481	0,58800	0,56876	0,49380	0,6
Poč.příp	4,00000					
Matice	3,00000					

Interpretace výsledků

a) Hierarchické shlukování – matice vzdáleností

Chceme odpověď na otázku: Který kraj je „typický“ (nejbližší všem ostatním)? A které jsou naopak zcela atypické?

1) Odstranit poslední čtyři případy

2) Označit všechny sloupce v matici vzdáleností, kliknout na hlavičku a dát „Statistiky bloku dat – Blok sloupců – Součty“

3) Ve vzniklé tabulce hledáme minima a maxima

Pocet_ob_31_12_2014													
1	2	3	4	5	6	7	8	9	10	11	12	13	14
Hlavní m													
Hlavní	0,0												
Středoče	0,7												
Jihočesk	3,8												
Plzeňský	3,9												
Karlovar	4,9												
Ústecký	3,6												
Libereck	4,3												
Královéh	4,0												
Pardubic	4,1												
Kraj Vys	4,1												
Jihomora	0,4												
Olomouck	3,8												
Zlínský	3,9												
Moravsko	0,2												

Context menu for the first column header:

- Vybrat pouze jména proměnných
- Statistiky bloku dat
- Grafy bloku dat
- Grafy vstupních dat
- Vymout
- Kopírovat
- Kopírovat se záhlavím
- Vložit
- Vložit jinak...
- Přidat proměnné...
- Odstanit proměnné...
- Přesunout proměnné...
- Kopírovat proměnné...
- Specifikace proměnné...
- Správce skupin...
- Vyplnit/standardizovat blok
- Odstanit

Context menu for the last column header:

- Blok sloupců
- Průměry
- Mediány
- Směr. odchylinky
- Počty platných
- Součty
- Minima
- Maxima
- Dolní quartily
- Horní quartily
- Všechny




Nejtypičtější je zde Zlínský kraj = je to takový „nejprůměrnější kraj“ v ČR z hlediska obyvatelstva v r. 2014

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Hlavní m	Středoče	Jihočesk	Plzeňský	Karlovar	Ústecký	Libereck	Královéh	Pardubic	Kraj Vys	Jihomora	Olomouck	Zlínský	Moravsko	
SOUČET případy 1-14	42,3753909	46,8152429	22,4286976	21,5198785	35,636125	30,7820631	26,4089376	21,72157	22,6015561	22,8891578	39,1483657	22,36326	21,618127	40,1113631

Interpretace výsledků

b) Metoda k-průměrů

- V tomto případě chceme shlukovat kraje, tzn. případy/řádky, a použijeme k tomu všechny proměnné
- Jelikož mi v předchozím případě vyšel ideální počet shluků jako 2, nastavím, že chci 2 shluky
- Minimální počet iterací je 20 (je možno nastavit i víc)



Budeme interpretovat následující tyto čtyři výstupy:
Členy shluků a vzdáleností,
graf průměrů, analýzu rozptylu

Interpretace výsledků

b) Metoda k-průměrů – členy shluků a vzdálenosti

- Vzniknou (v méém případě) dvě tabulky, z jedné na druhou lze překliknout v nabídce vlevo

	Členy shluku číslo 1 a vzdálenosti od příslušného shluku obsahujícího 10 příslušníků
	Vzdálen.
Hlavní město Praha	0,114569
Středočeský kraj	0,303784
Jihomoravský kraj	0,174756
Moravskoslezský kraj	0,105683

	Členy shluku číslo 1 a vzdálenosti od příslušného shluku obsahujícího 10 příslušníků
	Vzdálen.
Jihočeský kraj	0,246676
Plzeňský kraj	0,061152
Karlovarský kraj	0,802206
Ústecký kraj	0,818131
Liberecký kraj	0,364351
Královéhradecký kraj	0,043758
Pardubický kraj	0,122509
Kraj Vysočina	0,146375
Olomoucký kraj	0,239760
Zlínský kraj	0,090405

Je zjevné, že členy shluků jsou v tomto případě úplně stejné jako v předchozím.

Vzdálenost ve sloupci je vzdálenost od středu daného shluku – tzn. čím menší, tím „typičtější“ je daný kraj pro tento shluk.

Např. největší vzdálenost má Ústecký kraj – potvrzuje se, že je velmi odlišný.

Interpretace výsledků

b) Metoda k-průměrů – analýza rozptylu

- Analýzou rozptylu zde testujeme, které proměnné nejvíce ovlivnily rozřazení do shluků

Proměnná	Analýza rozptylu (Pocet_ob_31_12_2014)					
	Mezisk. SČ	sv	Vnitřní SČ	sv	F	význam. p
Počet obyv	10,90985	1	2,090148	12	62,63586	0,000004
PO_do14let	11,06982	1	1,930181	12	68,82146	0,000003
PO_15-64let	11,47141	1	1,528587	12	90,05502	0,000001
PO_nad65let	11,50356	1	1,496436	12	92,24768	0,000001


Hodnotu testové statistiky F zde můžeme interpretovat tak, že čím vyšší, tím větší byl vliv.

Tzn. proměnné počet obyvatel v kategorii 15–64 let a nad 65 let ovlivnily rozdělení více, než zbylé dvě proměnné.

Interpretace výsledků

b) Metoda k-průměrů – graf průměrů

- Graf průměrů ukazuje průměrnou hodnotu (osa y, bezrozměrné číslo) dané proměnné (osa x) pro konkrétní shluk (rozlišeny barevně).



Zde vidíme, že pro shluk číslo 1 je typický vysoký počet obyvatel, do druhého státy s nízkým počtem obyvatel.

Teoreticky by se také dalo říct, že druhý shluk má obecně více obyvatel ve všech třech kategoriích (0-14, 15-64 a 65+ let), což je samozřejmě nesmysl.

Jde o důsledek toho, že na začátku nebyla použita průzkumová analýza dat, která by prokázala korelací mezi proměnnými → správně bylo třeba provést nejdřív PCA!

Interpretace výsledků

- Pomineme-li špatné použití proměnných ke shlukování z důvodu chybějící průzkumové analýzy dat:
 - Pomocí obou metod vznikly dva shluky:
 - Praha, Jihomoravský kraj, Moravskoslezský kraj a Středočeský kraj
 - Jihočeský, Olomoucký, Plzeňský, Zlínský, Královéhradecký, Pardubice, Vysočina, Liberecký, Karlovarský, Ústecký
 - V prvním shluku jsou kraje s velmi mladou věkovou strukturou (nadprůměrný počet jedinců v kategorii do 14 let – lze zjistit po prohlédnutí tabulky standardizovaných dat)
 - Nejtypičtější v ČR je Zlínský kraj
 - Naopak nejméně typické byly Středočeský a Hlavní město Praha (z dat vyplynulo, že jde o důsledek enormně vysokého počtu obyvatel vůči ostatním krajům – zejména krajům 2. shluku)

Poznámka ke cvičení

- Cvičení bude obsahovat:
 - Pro hierarchické shlukování:
 - Dendogram,
 - rozvrh shlukování,
 - graf rozvrhu shlukování
 - matici vzdáleností
 - Pro nehierarchické shlukování:
 - Členy shluků a vzdáleností,
 - graf průměrů,
 - analýzu rozptylu
 - Výstupy budou ve vhodné podobě (tzn. čitelné a popsané, abych nemusela hádat, co vlastně je na obrázku)
- Pozor!
 - Máte jiná data, může vám jako optimální vyjít jiný počet shluků než 2
 - Pro napsání závěru si přečíst požadavky profesora Dobrovolného v pdf zadání (body 6–10)
 - Není potřeba popisovat teorii nebo „na ose x obr. 1 je tohle a tohle...“
 - v tomhle cvičení je totik výsledků, které se dají popsat a interpretovat, že by to klidně vyšlo na stránku

Poznámka ke cvičení

- Data ve cvičení: data o evropských zemích z r. 1979
- Zastoupení činného obyvatelstva v kategoriích:
 - Zemědělství
 - Těžba
 - Průmyslová výroba
 - Energetika
 - Stavebnictví
 - Místní hospodářství
 - Finance
 - Služby
 - Doprava a komunikace

Zdroje:

- BUDÍKOVÁ, Marie. Shluková analýza (přednáška). Brno: Masarykova univerzita, 9.5. 2016.
- DOBROVOLNÝ, Petr. Z2069 Statistické metody a zpracování dat II: Shluková analýza (přednáška) Brno: Masarykova univerzita, 9.5. 2016.