

Cvičení č. 3.: Aplikace shlukové analýzy

Článek Ladislava Rabušice Koho Češi nechtějí? (uveřejněn ve Sborníku prací FSS MU Sociální studia 5, 2000) se zabývá touto problematikou:

V roce 1999 proběhlo ve 24 evropských zemích sociologické šetření, v němž měli respondenti za úkol odpovědět na otázku „Můžete prosím z následujícího seznamu vybrat všechny ty, koho byste nechtěl(a) mít za sousedy?“

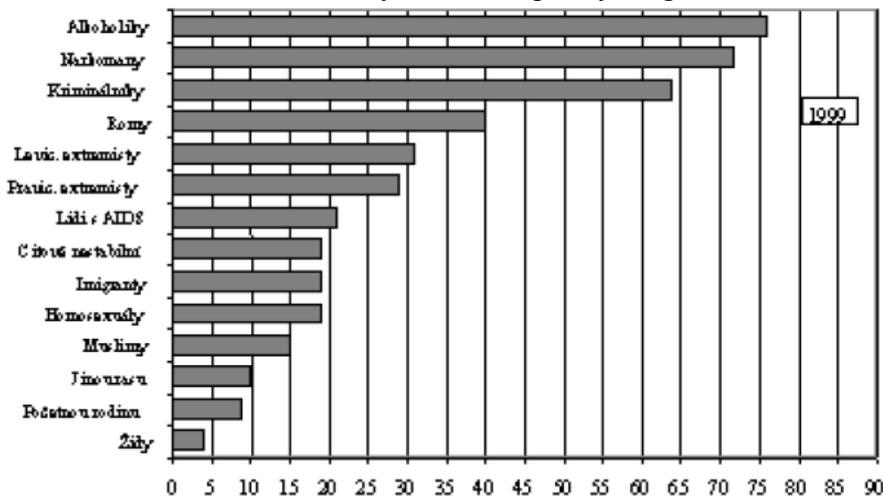
V seznamu byly tyto skupiny osob:

Kriminálníci, osoby jiné rasy, levicoví extrémisté, alkoholici, pravicoví extrémisté, početné rodiny, citově nestabilní lidé, muslimové, imigranti, lidé s AIDS, narkomani, homosexuálové, židé, Romové.

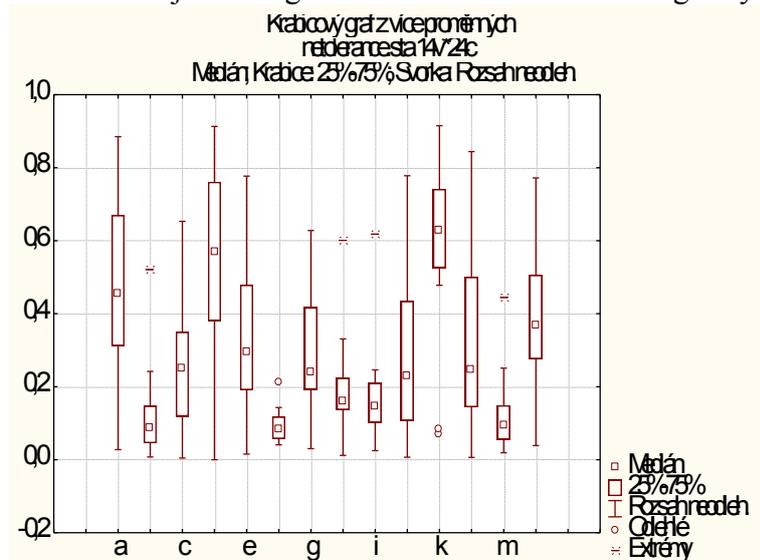
V datovém souboru netolerance.sta jsou zaznamenány relativní četnosti vybraných skupin osob.

V České republice se výzkumu, který proběhl v květnu 1999, zúčastnilo 1908 osob.

Úkol 1.: Zaměřte se na ČR. Vytvořte sloupkový diagram tohoto tvaru:

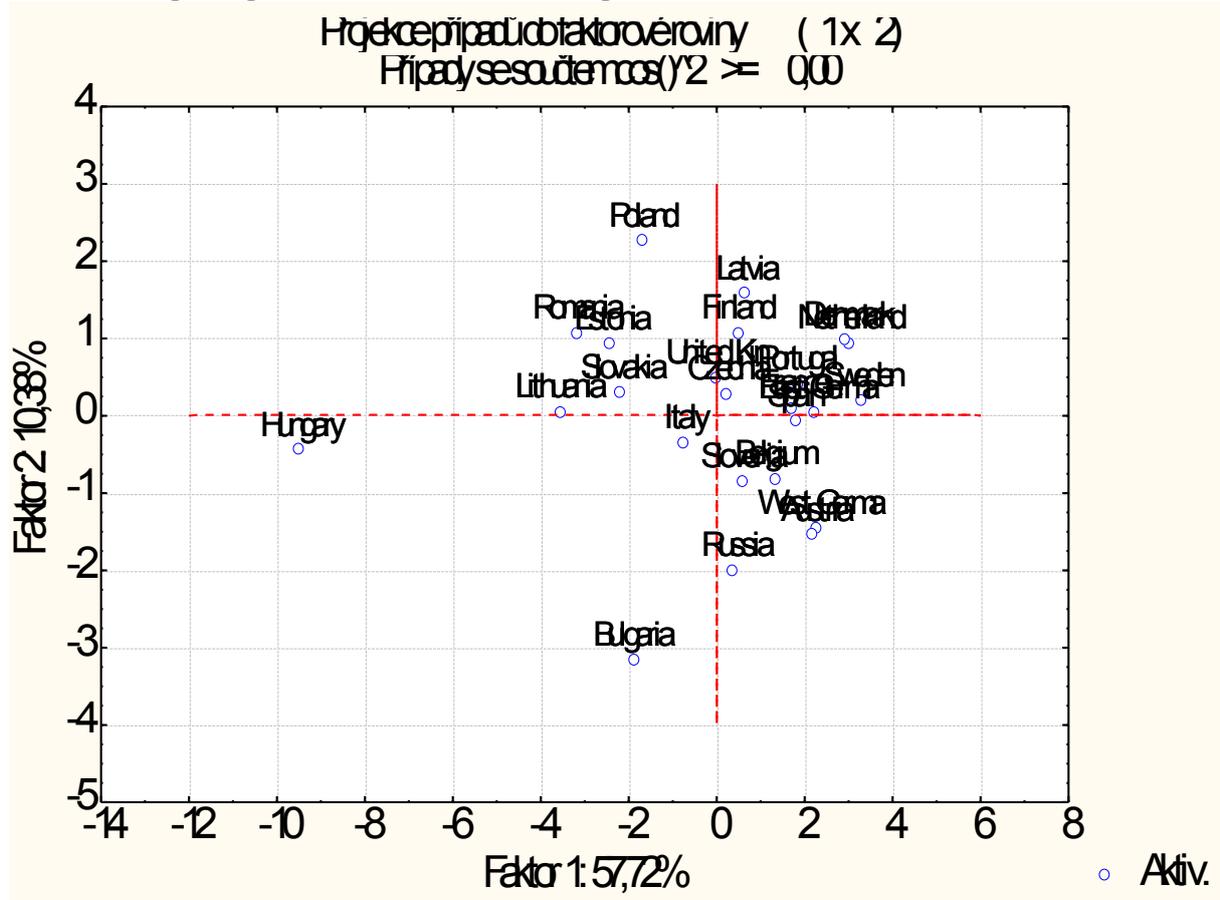


Úkol 2.: Do jednoho grafu nakreslete krabicové diagramy všech 14 proměnných.



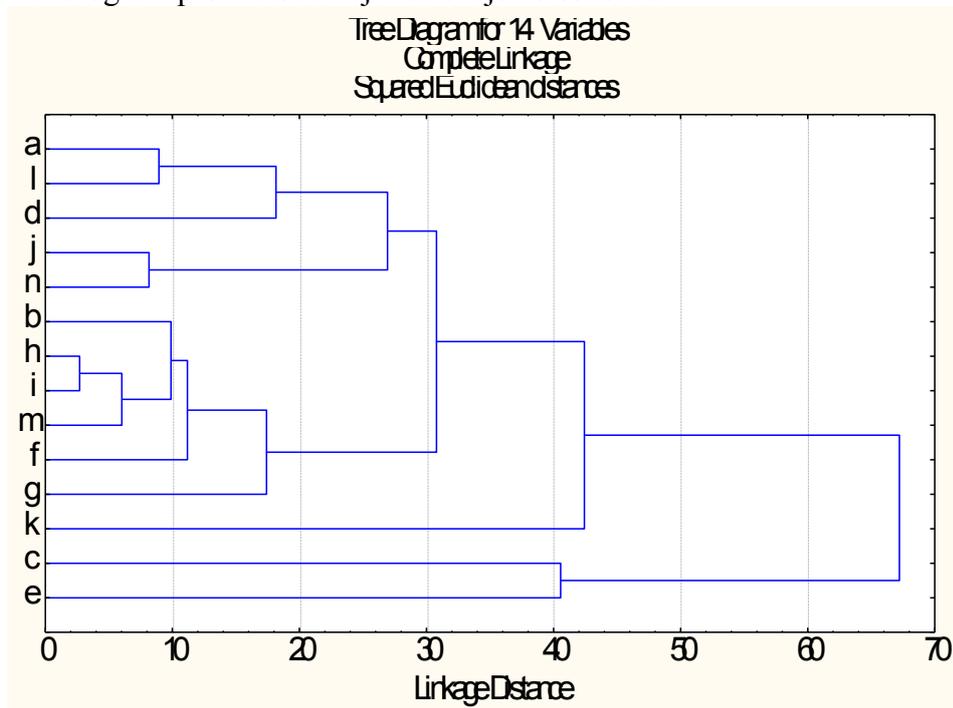
Vzhledem k velmi rozdílné variabilitě proměnných se jeví vhodnější pracovat se standardizovanými daty.

Úkol 3.: Na ploše prvních dvou hlavních komponent znázorněte rozmístění zemí.



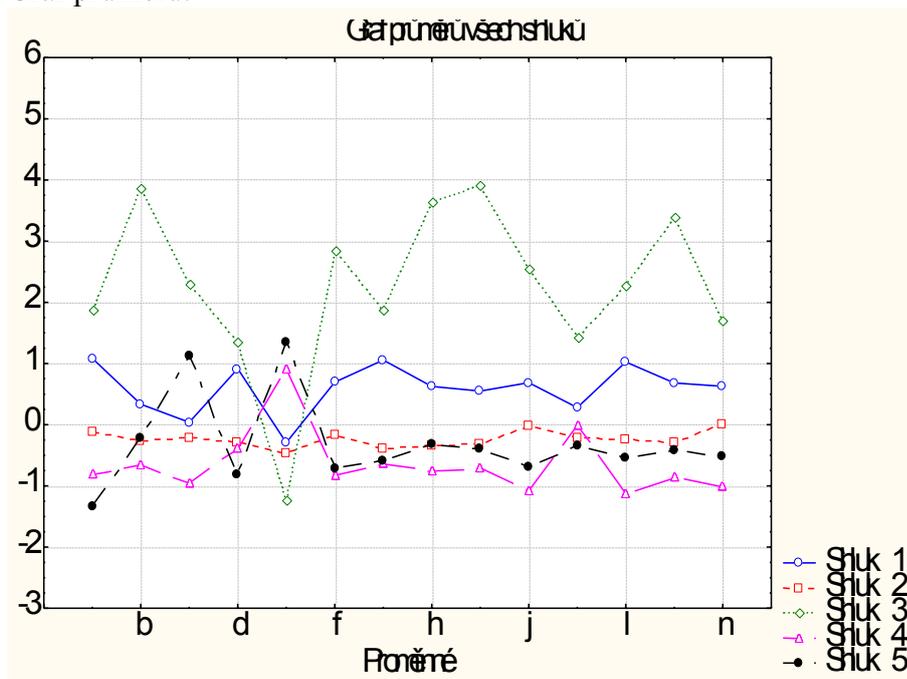
Úkol 5.: Určete 5 shluků navzájem si podobných zemí.

Úkol 6.: Proveďte shlukovou analýzu pro proměnné.
Dendrogram pro metodu nejvzdálenějšího souseda:



Úkol 7.: Použijte metodu k-průměrů k nalezení 5 shluků navzájem si podobných zemí a uložte skupinovou příslušnost do datového souboru. K určení významnosti jednotlivých proměnných proveďte analýzu rozptylu. Nakreslete graf průměrů všech 5 shluků a pokuste se o interpretaci.

Graf průměrů:



Příklad k samostatnému řešení:

(Příklad je převzat z knihy M. Meloun, J. Militký, M. Hill: Počítačová analýza vícerozměrných dat. Academia Praha 2005)

U 12 velmi slavných amerických hráčů košikové byly v sezóně 1989 zjištěny hodnoty osmi proměnných.

Výška – výška hráče v cm

Hmotnost – hmotnost hráče v kg

FgPct – první antropometrická charakteristika

FtPct – druhá antropometrická charakteristika

Body – průměrný počet dosažených bodů

Doskoky - průměrný počet doskoků

Asistence – průměrný počet asistencí

Fauly – průměrný počet faulů

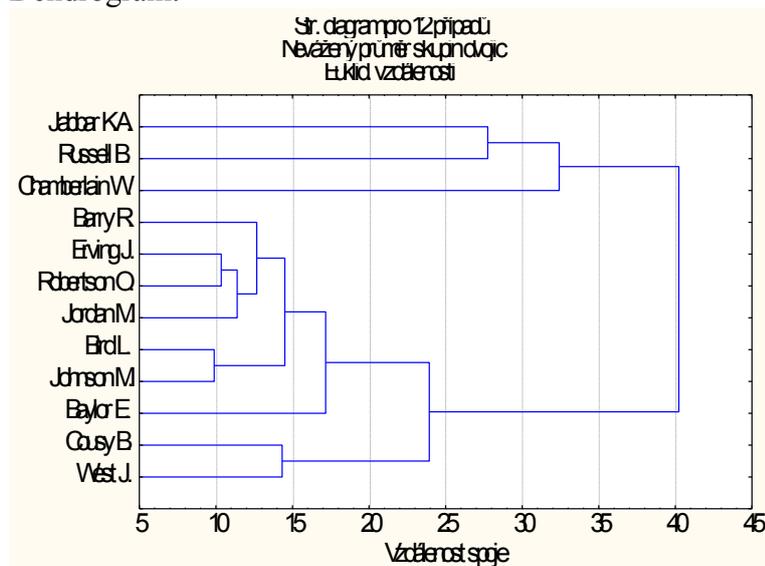
Data jsou uložena v souboru hraci.sta.

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|----|----------------|------|-------|-----|-----|-----|-------|---------|-----|
| | Jméno hráče | Výšk | Hmotn | Fgp | Ftp | Boc | Doskc | Asister | Fau |
| 1 | Jabbar K. | 218 | 105 | 55 | 72 | 24 | 11 | 3 | 3 |
| 2 | Barry R. | 200 | 93 | 44 | 90 | 23 | 6 | 4 | 3 |
| 3 | Baylor E. | 195 | 102 | 43 | 78 | 27 | 13 | 4 | 3 |
| 4 | Bird L. | 205 | 100 | 50 | 88 | 25 | 10 | 6 | 2 |
| 5 | Chamberlain W. | 216 | 125 | 54 | 51 | 30 | 22 | 4 | 2 |
| 6 | Cousy B. | 184 | 79 | 37 | 80 | 18 | 5 | 7 | 2 |
| 7 | Erving J. | 199 | 91 | 50 | 77 | 24 | 8 | 4 | 2 |
| 8 | Johnson M. | 205 | 98 | 53 | 83 | 19 | 7 | 11 | 2 |
| 9 | Jordan M. | 198 | 89 | 51 | 84 | 32 | 6 | 5 | 3 |
| 10 | Robertson O. | 195 | 95 | 48 | 83 | 25 | 7 | 9 | 2 |
| 11 | Russell B. | 207 | 100 | 44 | 56 | 15 | 22 | 4 | 2 |
| 12 | West J. | 189 | 82 | 47 | 81 | 27 | 5 | 6 | 2 |

Metodou průměrné vazby s euklidovskými vzdálenostmi najděte 3 skupiny hráčů podobných vlastností. Výsledek ověřte metodou k-průměrů.

Výsledky

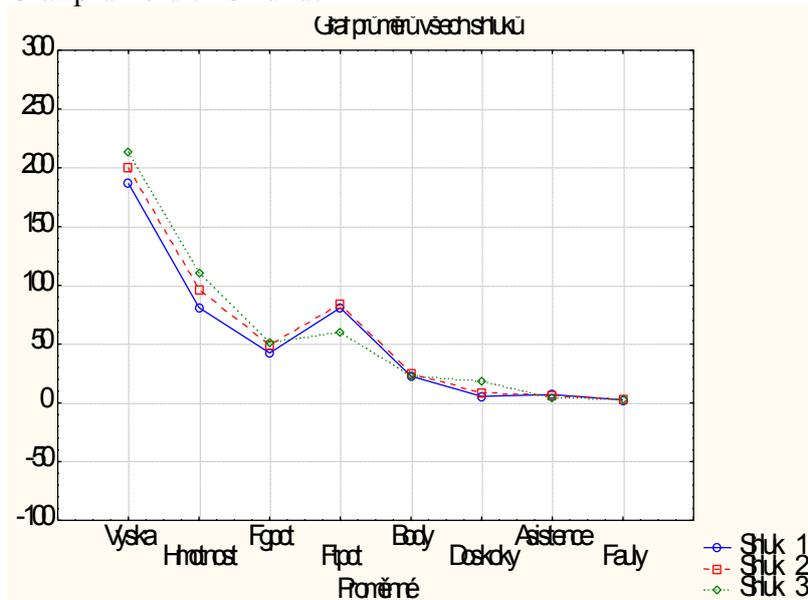
Dendrogram:



Rozdělení hráčů do 3 shluků metodou k-průměrů:

| Cleny shluku cislo 1 (hrac a vzdalenosti od prislusne Shluk obsahuje 2 prip.) | |
|---|------------|
| | Vzdalenost |
| Cousy B. | 2,532 |
| West J. | 2,532 |
| Cleny shluku cislo 2 (hrac a vzdalenosti od prislusne Shluk obsahuje 7 prip.) | |
| | Vzdalenost |
| Barry R. | 2,995 |
| Baylor E. | 4,557 |
| Bird L. | 3,089 |
| Erving J. | 2,877 |
| Johnson M. | 3,738 |
| Jordan M. | 3,819 |
| Robertson C. | 1,951 |
| Cleny shluku cislo 3 (hrac a vzdalenosti od prislusne Shluk obsahuje 3 prip.) | |
| | Vzdalenost |
| Jabbar K.A. | 5,967 |
| Chamberlain W. | 6,905 |
| Russell B. | 6,030 |

Graf průměrů tří shluků:



Tabulka ANOVA:

| Proměření | Analýza rozptylu (hraci.sta) | | | |
|-----------|------------------------------|---------------|-------|---------|
| | Mezi s' SC | Vnitřní s' SC | F | význa p |
| Vyska | 905,4 | 194,4 | 20,95 | 0,000 |
| Hmotnost | 1051,2 | 505,9 | 9,34 | 0,006 |
| Fgpct | 97,2 | 207,9 | 2,10 | 0,177 |
| Ftpct | 1232,2 | 368,0 | 15,07 | 0,001 |
| Body | 16,2 | 249,3 | 0,29 | 0,752 |
| Doskovy | 287,4 | 127,7 | 10,12 | 0,004 |
| Asistence | 15,6 | 44,9 | 1,56 | 0,261 |
| Faly | 0,2 | 0,92 | 1,32 | 0,312 |