



# vodní hospodářství®

[www.vodnihospodarstvi.cz](http://www.vodnihospodarstvi.cz)

ročník 58

1  
2008



**hydrotech**  
[www.hydrotech-group.com](http://www.hydrotech-group.com)

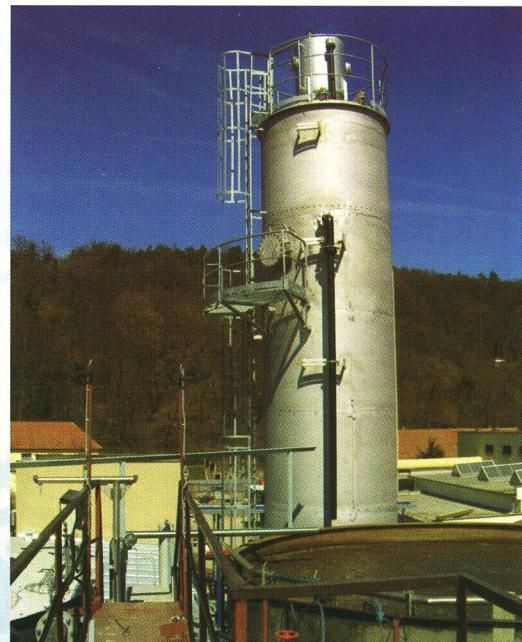


ČOV SHP Harmanec

**Mnoho štěstí a úspěchů  
v novém roce  
Vám přeje kolektiv firmy  
HYDROTECH s. r. o.**



Dosazovací nádrže vybavené technologií Zickert  
půdorys 2 x (12 x 85) m



ČOV Pivovar Černá Hora, a. s.

# Vracíme vodě život

Vodní hospodářství je recenzovaný časopis uznávaný Radou vlády ČR pro výzkum a vývoj a odborné články jsou sledovány v *Chemical Abstracts*



Moravská Třebová 1. - 2. 4. 2008

"Nové metody a postupy při provozování ČOV"  
tradiční odborný seminář XIII. ročník

pořádá VHOS, a.s. ve spolupráci s AČE ČR

program, přihlášky: [www.vhos.cz](http://www.vhos.cz)

informace: J. Kotoučková, telefon: 461 357 103, e-mail: [tr.sek@vhos.cz](mailto:tr.sek@vhos.cz)

**PŘÍLOHA**  
• ČL •

# Statistické zpracování vodohospodářských dat

## 8. Analýza říční vody vícerozměrným škálováním MDS

Milan Meloun

### Klíčová slova

vícerozměrné škálování – CMDS – NNMDS – stress – Shepardův graf – dendrogram znaků – dendrogram objektů – říční voda – graf komponentního skóre – indexový graf vlastních čísel – graf komponentních vah

### Souhrn

Subjektivní mapa relativního umístění objektů a znaků v rovině se tvoří na základě podobnosti či vzdáleností mezi objekty, tzv. matice proximity. Kritériem je těsnost proložení daty modelem MDS a Kruskalovo kritérium stress nebo Shepardův diagram. Analýza shluků patří mezi metody, které se zabývají vyšetřováním podobnosti vícerozměrných objektů, objektů, u nichž je změreno větší množství znaků a jejich klasifikaci do tříd čili shluků. Hodí se zejména tam, kde objekty projevují přirozenou tendenci se seskupovat. Taková klasifikace se nazývá numerická taxonomie. Umožňuje identifikaci vztahu, pomocí kterého je snadnější nalezení shluků a struktury všech objektů.

### 1. Úvod

Vícerozměrné škálování (MultiDimensional Scaling, MDS) je technika vytvoření diagramu relativního umístění objektů v rovině dvojrozměrného grafu na základě dat vzdáleností mezi objekty, tzv. matice proximity (blízkosti). Diagram může obsahovat jeden, dva, tři a zřídka i více rozměrů, dimenzí. Technika vychází buď přímo z experimentálních hodnot  $X$ , z korelační matice  $R$  nebo z matice podobnosti  $s$  či vzdáleností  $D$ . Vzdálenost mezi oběma objekty je Euklidovská, počítaná na základě Pythagorovy

věty,  $d_{ij} = \sqrt{\sum_{k=1}^m (x_{ik} - x_{jk})^2}$ , kde  $m$  je počet proměnných a  $x_{ik}$  jsou data  $i$ -tého řádku a  $k$ -lého sloupce. I když vynášíme vzdálenosti do dvojrozměrného grafu, může být  $d_{ij}$  vyčísleno na základě většího počtu proměnných  $m \geq 2$ . Matice vzdáleností je potom trojúhelníková a zajímá nás jenom její horní část. S růstem objektů však roste i počet dimenzí, takže pro tři objekty je to dvoj-rozměrná rovina, pro čtyři objekty pak troj-rozměrný prostor, atd.

### 2. Teoretická část

Kritérium maximální věrohodnosti ukazuje, jak těsně prokládá model vzdáleností daná experimentální data. Hodnotí se testem těsnosti proložení s využitím statistického kritéria stress, založeného na rozdílu mezi skutečnou vzdáleností  $d_{ij}$  a její modelem predikovanou hodnotou  $\hat{d}_{ij}$ ,

$$\text{stress} = \sqrt{\frac{\sum_{i,j}^m (d_{ij} - \hat{d}_{ij})^2}{\sum_{i,j}^m d_{ij}^2}}$$

kde  $\hat{d}_{ij}$  je predikovaná vzdálenost, založená na MDS modelu. Predikovaná hodnota závisí především na počtu užitých dimenzí a algoritmu, a to metrickém či nemetrickém. Je-li stress číslo nízké, blízké nule, jeví se MDS proložení jako nejlepší.

**Počet dimenzí:** důležitým úkolem v MDS je určení počtu dimenzí v MDS modelu. Každá dimenze pak představuje latentní proměnnou. Cílem MDS je udržet počet dimenzí na co možná nejmenší hodnotě. Obvykle volí uživatel dvoj- maximálně trojrozměrný prostor. Vychází-li vyšší počet dimenzí, není MDS technika vhodná k analýze dolyčných dat. Počet dimenzí se volí na základě co

nejmenší hodnoty kritéria stress. Někteří autoři si pomáhají Cattelovým indexovým grafem relativní velikosti vlastních čísel, která jsou vyčíslována pro rostoucí počet dimenzí, zvaným také graf úpatí. Postup a interpretace jsou pak stejné jako u metod PCA nebo FA.

**Vstupní data:** data mohou být trojího typu, a to mohou obsahovat (1) vzdálenosti mezi objekty  $D$ , (2) podobnost mezi objekty  $s$  nebo (3) hodnoty znaků (sloupce) pro jednotlivé objekty (řádky)  $X$ .

**Vzdálenost (disimilitance)**  $d_{ij}$  představující vzdálenost mezi objekty, může být měřena přímo, jako např. vzdálenost dvou měst. Matice vzdáleností  $D$  je symetrická.

**Podobnost (similarita)**  $s_{ij}$  vyjadřuje jak těsně se nacházejí dva objekty. MDS umožňuje načít míry podobnosti pro každý pár objektů. Matice podobnosti  $s$  je opět symetrická. Podobnost lze konvertovat do veličiny vzdálenost vzorcem  $d_{ij} = \sqrt{s_{ii} + s_{jj} - 2s_{ij}}$ , kde  $d_{ij}$  představuje vzdálenost a  $s_{ij}$  podobnost.

**Hodnoty**  $x_{ij}$  proměnných pro jednotlivé objekty představují spíše standardní míry. Z nich se vypočte nejprve korelační matice  $R$  a potom matice Eukleidovských či Mahalanobisových vzdáleností  $D$ .

**Klasická metrická metoda MDS:** je dána matice vzdáleností  $D$ , která vystihuje meziobjektové vzdálenosti objektů  $X$  v prostoru spíše nižšího rozměru dle vzorce

$$d_{ij} = \sqrt{\sum_{k=1}^m (x_{ik} - x_{jk})^2}$$

Jednotlivé kroky klasické MDS jsou následující:

1. Z  $D$  se vypočte  $a = \{-0.5 d_{ij}^2\}$ .
2. Z  $a$  se vypočte  $B = \{a_{ij} - a_i - a_j + a\}$ , kde  $a_i$  je průměr všech  $a_{ij}$  přes  $j$ .
3. Nalezně se  $m$  největších vlastních čísel  $\lambda_1 > \lambda_2 > \dots > \lambda_m$  matice  $B$  a odpovídající vlastní vektory  $L = L_{(1)}, L_{(2)}, \dots, L_{(m)}$ , které jsou normovány, takže  $L_{(ij)}^T L_{(ij)} = \lambda_i$ . Předpokládáme, že  $m$  je voleno tak, že vlastní hodnoty jsou relativně velké a kladné.
4. Souřadnicemi objektů jsou řádky matice  $L$ .

Klasické řešení je optimalizované metodou nejmenších čtverců: přímé řešení  $L$  minimalizuje sumu čtverců vzdáleností mezi skutečnými prvky matice  $D$ , tj.  $d_{ij}$  a predikcemi  $\hat{d}_{ij}$ , založenými na  $L$ . Předpokládejme, že experimentální hodnoty vzdálenosti  $d_{ij}$  jsou zatíženy náhodnou chybou  $\varepsilon_{ij}$  dle vzorce  $d_{ij} = \delta_{ij} + \varepsilon_{ij}$ , kde  $\varepsilon_{ij}$  představuje kombinaci náhodných chyb z měření distorze vzdáleností, když MDS model zcela neodpovídá konfiguraci navržených  $m$  vzdáleností. Navrhne model závislosti mezi vzdáleností dvou objektů vztahem  $\hat{d}_{ij} = \beta_0 + \beta_1 \delta_{ij} + \varepsilon_{ij}$  a potom nalezením nejlepších odhadů  $b_0$  pro  $\beta_0$  a  $b_1$  pro  $\beta_1$  obdržíme odhad vypočtené vzdálenosti  $\hat{d}_{ij} = \beta_0 + \beta_1 \delta_{ij}$ . Optimalizační procedura vychází z účelové funkce

$$U = \sum_{i,j}^n (d_{ij} - \hat{d}_{ij})^2 = \text{minimum}$$

Aby byla zajištěna úplná invariantnost vůči transformaci proměnných, užívá se modifikovaná účelová funkce  $U_{\text{mod}}$  dle

$$U = \frac{\sum_{i,j}^n (d_{ij} - \hat{d}_{ij})^2}{\sum_{i,j}^n d_{ij}^2}$$

a především její druhá odmocnina,

zvaná  $\text{stress} = \sqrt{U_{\text{mod}}}$ . Je proto výhodné hledat optimální počet dimenzí, které se vezmou k výpočtu predikce MDS vzdálenosti  $\hat{d}_{ij}$  pomocí minimální hodnoty veličiny stress. Pro  $\text{stress} < 0.05$  je těsnost proložení ještě přijatelná a pro  $\text{stress} < 0.01$  je těsnost proložení výtečná.

**Nemetrická MDS:** v dosavadním postupu se předpokládalo, že vzdálenosti jsou vyčísleny metricky. Jsou však situace, kdy jedna hodnota nevystihuje dostatečně skutečnost: např. při porovnávání barev na stupnici může být jedna barva zářivější než druhá, a tento fakt však nikterak neovlivní polohu barvy na stupnici. Predikované vzdálenosti  $\hat{d}_{ij}$  jsou vyčíslovány monotonní regresí: experimentální vzdálenosti jsou uspořádány vzestupně do řady

$$d_{11,12} \leq d_{12,13} \leq \dots \leq d_{1N,1N}, \text{ kde } N = n(n-1)/2$$

a  $\hat{d}_{ij}$  jsou odhadovány tak, aby splnily podmínu *slabé monotonicity (WM)*

$$\hat{d}_{i1j1} \leq \hat{d}_{i2j2} \leq \dots \leq \hat{d}_{iNjN},$$

nebo podmínu *silné monotonicity (SM)*

$$\hat{d}_{i1j1} < \hat{d}_{i2j2} < \dots < \hat{d}_{iNjN}.$$

Prvním krokem k získání počátečních odhadů predikovaných vzdáleností  $\hat{d}_{ij}$  bývá vždy metrické vyčíslení. Pak následuje nemetrický přístup monotonní regrese. Indexový graf úpatí veličiny stress je i u nemetrické metody užitečnou pomůckou. Hledá se jednak zlom na tomto grafu a jednak se vyšetruje, když veličina stress nabýde hodnot menších než 0.05, resp. 0.01. Takový index čili počet dimenzí se pak jeví jako optimální. Obdobně jako metrická metoda CMDS, ústí i nemetrická NNMDs ve vícerozměrné škálovací mapě, na které se sleduje rozdílení vyšetřovaných objektů.

### 3 Pracovní postup MDS

#### 3.1 Cíle vícerozměrného škálování objektů

Subjektivní mapování objektů technikou vícerozměrného škálování je výhodné k identifikování dosud nepoznaných znaků ovlivňujících chování objektů nebo jako způsob porovnávání objektů, když jiný specifický základ porovnání není předem znám. Síla subjektivního mapování objektů spočívá právě ve schopnosti vyvozovat své závěry, úsudky bez předešlého definování sledovaných proměnných, čili vlastností nebo i znaků objektu. Základním problémem v subjektivním mapování objektů je identifikace všech významných objektů, které se budou hodnotit. Musíme se ubezpečit, že všechny vyšetřované objekty jsou správně zahrnuty do dat, protože subjektivní mapování objektů je technika jejich relativního rozmístění na mapě a vzájemné porovnání jejich významnosti.

#### 3.2 Formulace úlohy vícerozměrného škálování objektů

Uvedeme čtyři etapy od výběru objektů a znaků až ke specifickým metodologickým problémům: prvním přístupem je *dekompoziční (rozkladná) metoda* bez užití znaků, která měří pouze celkový dojem při hodnocení objektu a pak vypočte polohu objektu ve vícerozměrném prostoru objektů, která tento dojem vystihne. *Kompoziční (skladná) metoda* při užití znaků je alternativním přístupem, který využívá několika vícerozměrných technik, již diskutovaných při tvorbě samotného dojmu o objektu. Je totiž založena na kombinaci více posuzovaných znaků o objektech.

**a) Dekompoziční metoda bez užití znaků.** Dekompoziční metody spojené s vícerozměrným škálováním objektů se týkají celkových měr podobnosti, ze kterých se vytvářejí subjektivní mapy objektů a v nich relativní umístění objektů. Charakteristikou pro vícerozměrné škálování objektů je bohatá paleta možných dekompozičních technik.

**b) Kompoziční metoda při užití znaků.** Kompoziční metody zahrnují několik tradičních vícerozměrných technik, například diskriminační analýzu nebo faktorovou analýzu, stejně jako metody speciálně navržené pro subjektivní mapování objektů, jako je korespondenční analýza. Společným základem je soubor znaků, který zde slouží k výpočtu podobnosti objektů. Výhodou je explicitní popis souřadnic subjektivního prostoru objektů. Mapování objektů může být provedeno technikou kompoziční i dekompoziční. Když jsou však znaky založeny na základě předem definovaného souboru vlastností, pak jsou preferovány kompoziční techniky.

**c) Data podobnosti objektů.** U podobnostních dat se uživatel snaží určit, které objekty jsou vzájemně podobnější a které jsou méně podobné. Výrazy podobnost a nepodobnost objektů jsou zaměnitelné v procesu popisu rozdílů mezi objekty. Při měření podobnosti je možnost porovnávat všechny páry objektů.

#### 3.3 Předpoklady vícerozměrného škálování objektů

Vícerozměrné škálování objektů nemá sice omezující požadavky na metodologii, typ dat, formu vztahu mezi znaky, ale vyžaduje, aby uživatel přijal několik zásad o datech: a) *Kolísání ve volbě znaků*. Každý respondent si musí uvědomit, že objekty musí mít stejnou dimenzi čili stejné znaky, i když většina respondentů chce usuzoval v pojmech svých oblíbených znaků. b) *Kolísání v důležitosti znaků*. Respondenti nemusí dávat stejnou důležitost určitému znaku, i když ostatní respondenti tento znak upřednostňují. c) *Kolísání v čase*. Úsudek o objektu nebo hladiny důležitosti nemusí

být stabilní v čase. Jinými slovy nelze očekávat, že si respondenti zachovají stejný úsudek po dlouhé časové období.

#### 3.4 Nalezené řešení a dosažená těsnost proložení

Počet počítacových programů pro vícerozměrné škálování objektů stále roste. Prvním krokem respondenta při určení polohy objektu na mapě je co nejlépe vystihnout vyhodnocovanou podobnost. Postup určení optimálních poloh objektů ve vícerozměrném škálování má čtyři fáze:

a) Vybere se počáteční sestava podnětlů, znaků, vlastností  $S_{ij}$  při požadovaném počtu souřadnic, který je založen na předešlých datech. Z velkého počtu možností může být optimální sestava také generována pomocí pseudonáhodných čísel přibližně normálního vícerozměrného rozdělení.

b) Vypočtu se vzdálenosti mezi body objektů  $d_{ij}$  v počáteční konfiguraci a porovnávají se se vzdálenostmi  $\hat{d}_{ij}$  vyčíslenými z jejich odhadů podobnosti  $S_{ij}$ . Rozdíly ve vzdálenostech objektů čili v reziduích jsou cílem vyčíslení míry těsnosti proložení stress.

c) Jestliže míra těsnosti proložení stress nedosáhne předem zadané hodnoty terminačního kritéria, naleze se nová konfigurace objektů, pro kterou je míra těsnosti proložení minimalizována. Program určí směry, ve kterých je dosaženo největšího zlepšení těsnosti proložení a přemístí body na mapě v těchto směrech.

d) Po dosažení uspokojivé hodnoty terminačního kritéria stress je počet souřadnic snížen o 1 a proces je opakován, dokud není dosaženo nejnižšího počtu souřadnic s přijatelnou těsností proložení. Určení počtu souřadnic je obecně možné některým z přístupů jako je subjektivní vyhodnocení objektů, nakreslení Cattelova indexového grafu úpatí pro veličinu stress, nebo zhodnocení těsnosti proložení. Prostorová mapa objektů je vhodnou počáteční pomůckou. Cílem je získat co nejlepší těsnost proložení při nejmenším možném počtu souřadnic. Interpretace řešení, odvozeného pro více než tři souřadnice, je obtížná a nepomůže zlepšit těsnost proložení. Druhý přístup spočívá ve využití míry stress, jež ukazuje podíl rozptýlení objektů, který nebyl vyčíslen modelem MDS. Kruskalova míra stress je nejužívanější formulací této míry těsnosti proložení modelem, který obsahuje jednak průměrnou vzdálenost objektů na mapě  $\bar{d}$  a dále zde  $\hat{d}_{ij}$  vyjadřuje vypočtenou vzdálenost objektů z podobnostních dat a konečně  $d_{ij}$  značí skutečnou vzdálenost z respondentova názoru. Stress se zmenšuje, čím více se blíží vypočtená vzdálenost  $\hat{d}_{ij}$  původní skutečné vzdálenosti objektů  $d_{ij}$ . Stress je počítacovým algoritmem minimalizován tak, že vypočtené vzdálenosti mezi objekty se blíží co nejlépe ke skutečným, tj. zadaným vzdálenostem. Kruskal vysvětluje empirické hodnoty veličiny stress k vystížení těsnosti proložení následovně: stress okolo 0.20 značí nedostatečné proložení, 0.10 dostatečné, 0.05 dobré, 0.025 výlečné a 0.00 naprostě perfektní. Ukazuje se, že hodnota stress závisí však na kvalitě matic vzdáleností a na počtu objektů v matici proximit. Jako při určení faktorů ve faktorové analýze můžeme vynést i zde závislost míry stress na počtu souřadnic a z polohy zlomu na křivce určit nejlepší počet dimenzí potřebných k analýze objektů.

Třetím krokem je sestrojení *Shepardova diagramu*. Jde o rozptylový diagram, ve kterém vynášíme vypočtené vzdálenosti  $\hat{d}_{ij}$  pro zvolený počet souřadnic (osa y) v závislosti na zadaných hodnotách (osa x). Diagramem je schodovitě klesající křivka, která představuje vypočtené vzdálenosti mezi dvěma objekty jako výsledek monotónní transformace zadaných vzdáleností. Když všechny vypočtené body padnou na schodovitou křivku, je dosaženo těsného proložení. Když naopak dojde k odchylkám od křivky, je dosaženo nedostatečného proložení.

#### 3.5 Interpretace výsledků

Když získáme subjektivní mapu objektů, rozlišují se obvykle dva způsoby interpretace výsledků, a to způsob kompoziční a způsob dekompoziční. Pro kompoziční metody musí být ověřena subjektivní mapa objektů ve vztahu k ostatním míram pohledu, vnímání, dojmu, protože polohy jsou jasně definovány znaky specifikovanými uživatelem. Pro dekompoziční metody je nejdůležitějším problémem popis subjektivních souřadnic a jejich vztah ke znakům. Znovu v souladu se svými znaky poskytují dekompoziční metody počáteční pohled do dojmů, ze kterých se pak vytvářejí formálnější názory.

#### 3.6 Ověření výsledků

Ověření vícerozměrného škálování objektů je stejně důležité jako v ostatních vícerozměrných technikách. Nejčastěji je porovnání mezi objekty provedeno vizuálně nebo pouze jednoduchou korelací souřadnic.

**Vzorová úloha 1** Vícerozměrné škálování v analýze kvality vody

Na datech analýzy vody řeky Vltavy bude ukázána metoda vícerozměrného škálování. Data byla získána monitrováním toku řeky Vltavy na stálých odběrových místech mezi Hlubokou a Kolodějem 1 až 7 v období od 20. 5. 1996 do 20. 6. 1997. Zdrojová matice je tvořena 12 ukazateli jakosti základního chemického rozboru pitných a povrchových vod ve sloupcových znacích a 47 řádky, kódujícími místo a čas odběru ve sloupci znaku **Objekt**. Zde první číslice identifikuje odběrové místo a druhé dvě číslice pak měsíc odběru. Nejistota obsahů a koncentrace prvků byla odhadnuta z testů způsobilosti akreditačního střediska ASLAB. Vícerozměrným škálováním se posoudí podobnost 12 ukazatelů kvality vody a vzorků míst odběru vody (objekty) způsobem "každého s každým". Je třeba provést *dvojrozměrné škálování* a z výsledného grafu posoudit na podobné a nepodobné ukazatele kvality vody a odběrová místa. Vedle metody klasického metrického škálování CMDS a nemetrického škálování NNMDS provedeme v rámci exploratorní analýzy také analýzu hlavních komponent, faktorovou a shlukovou analýzu.

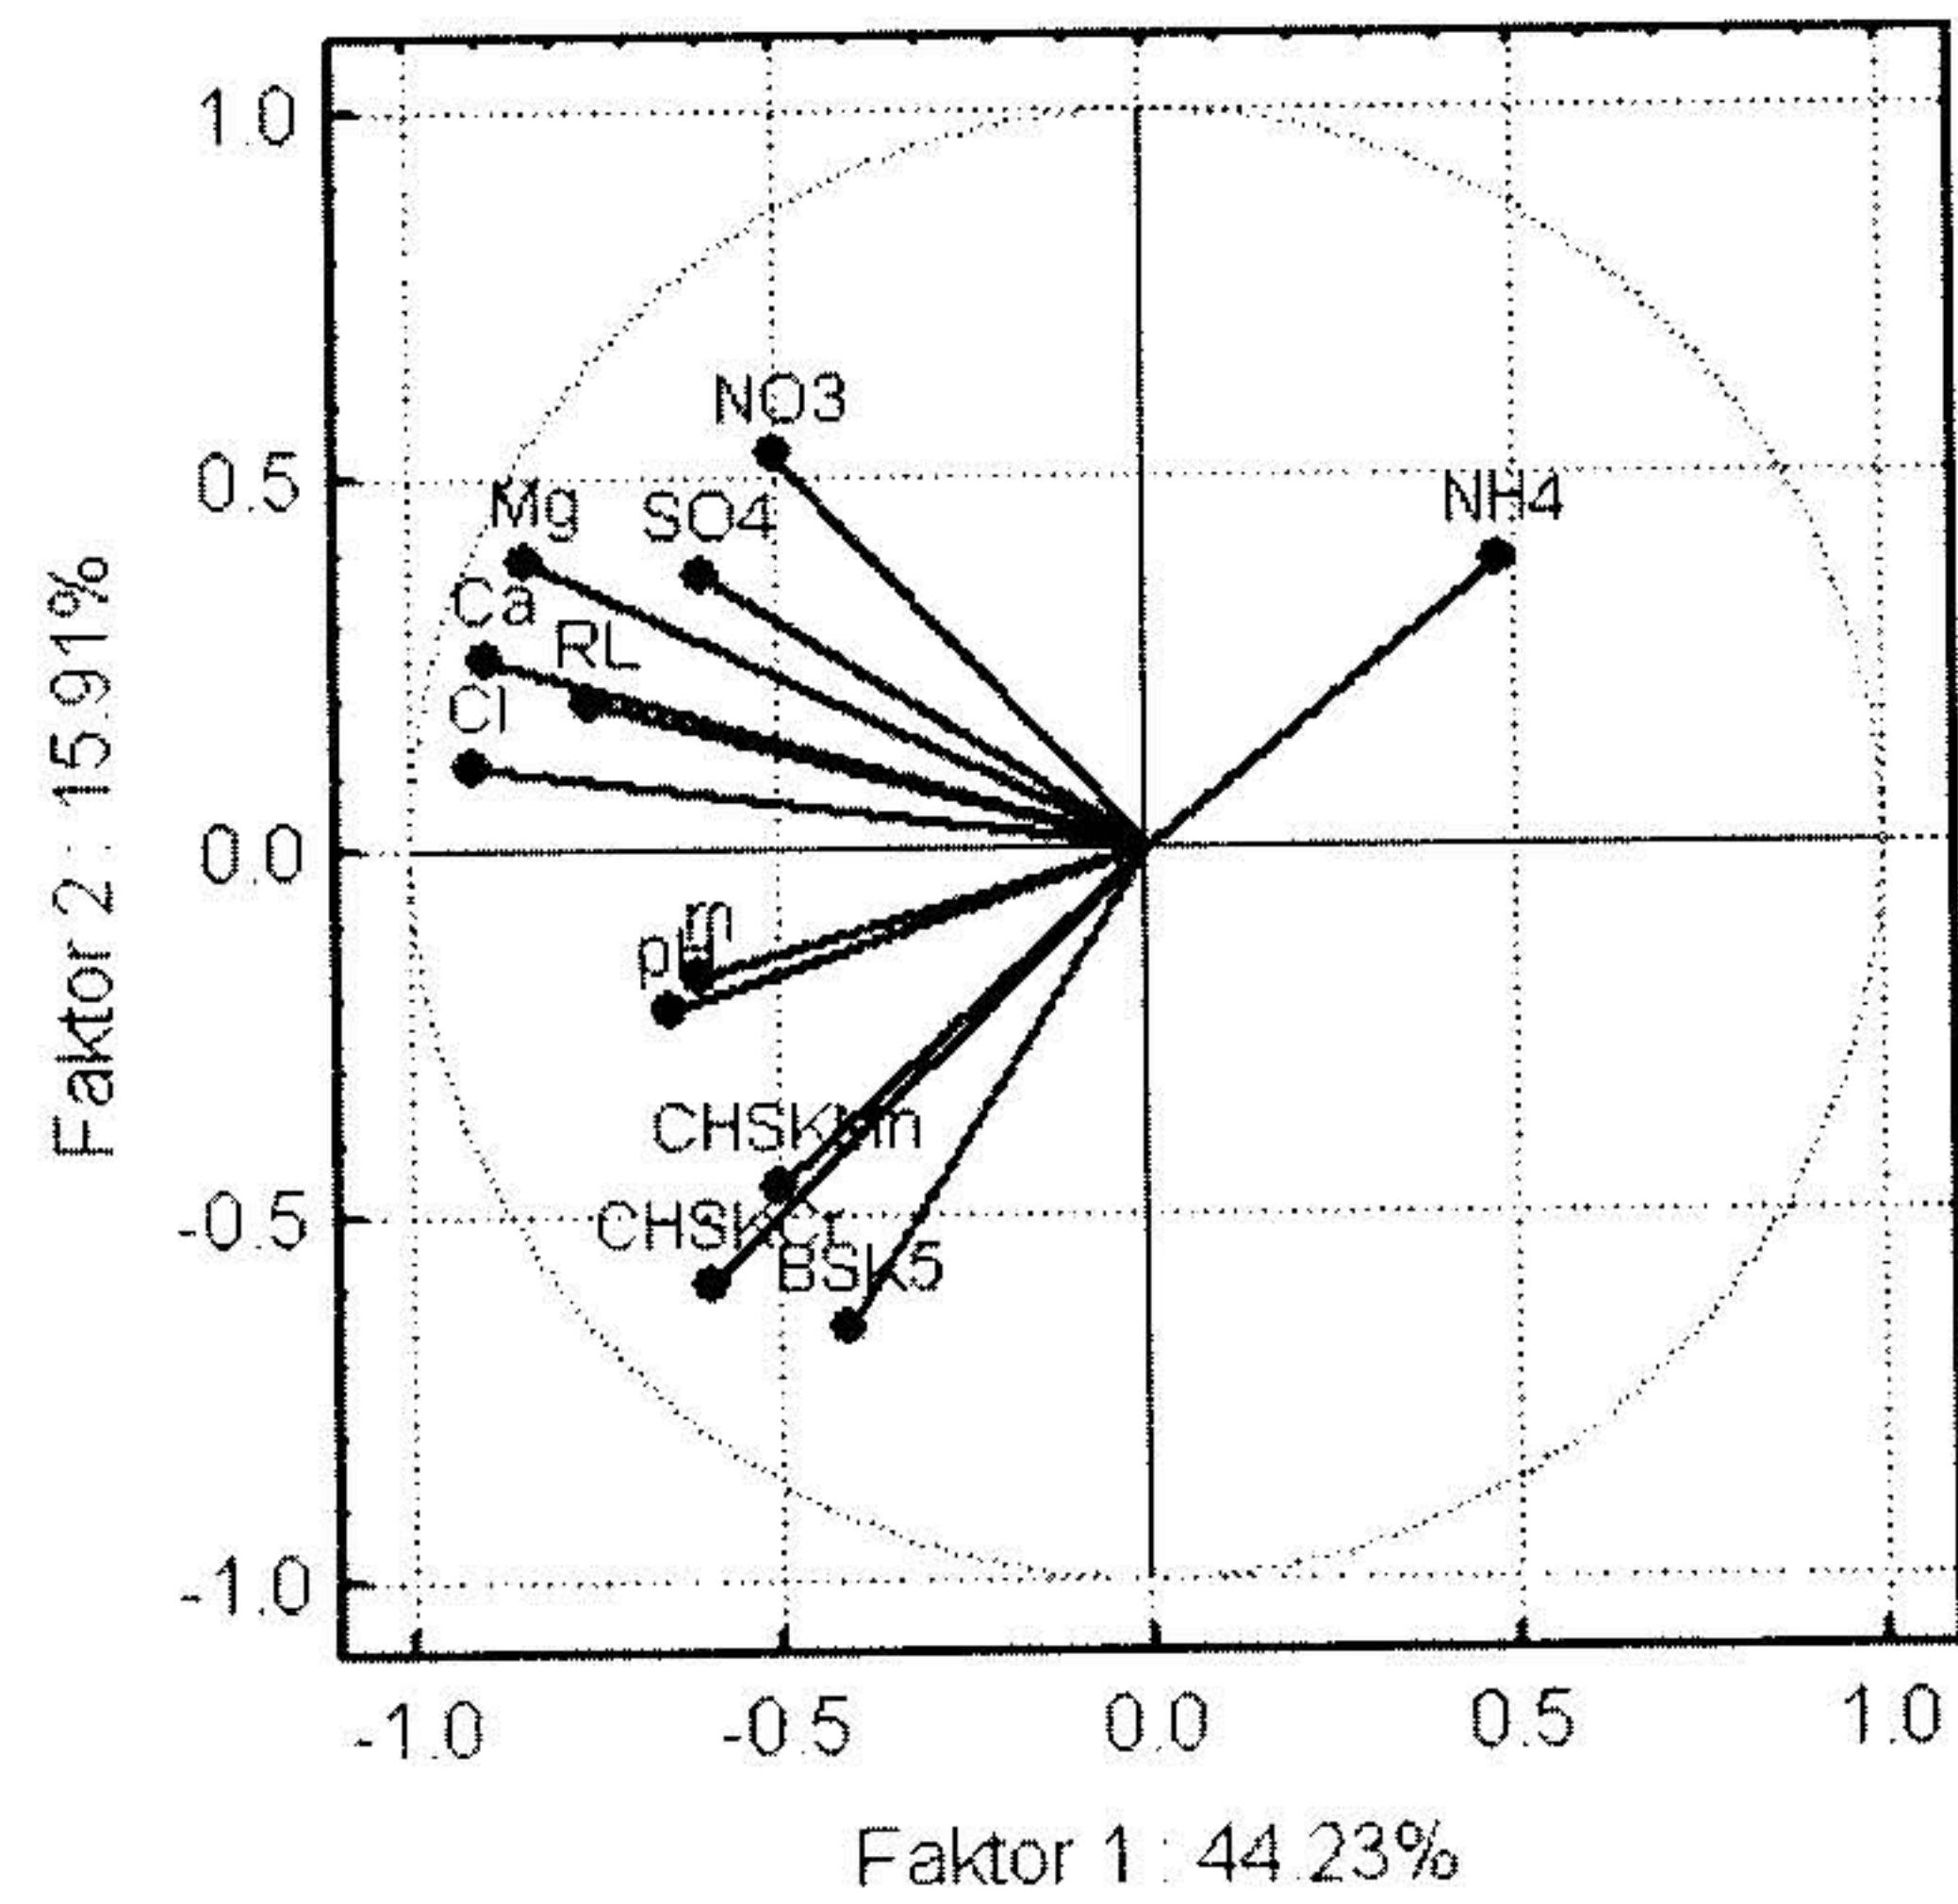
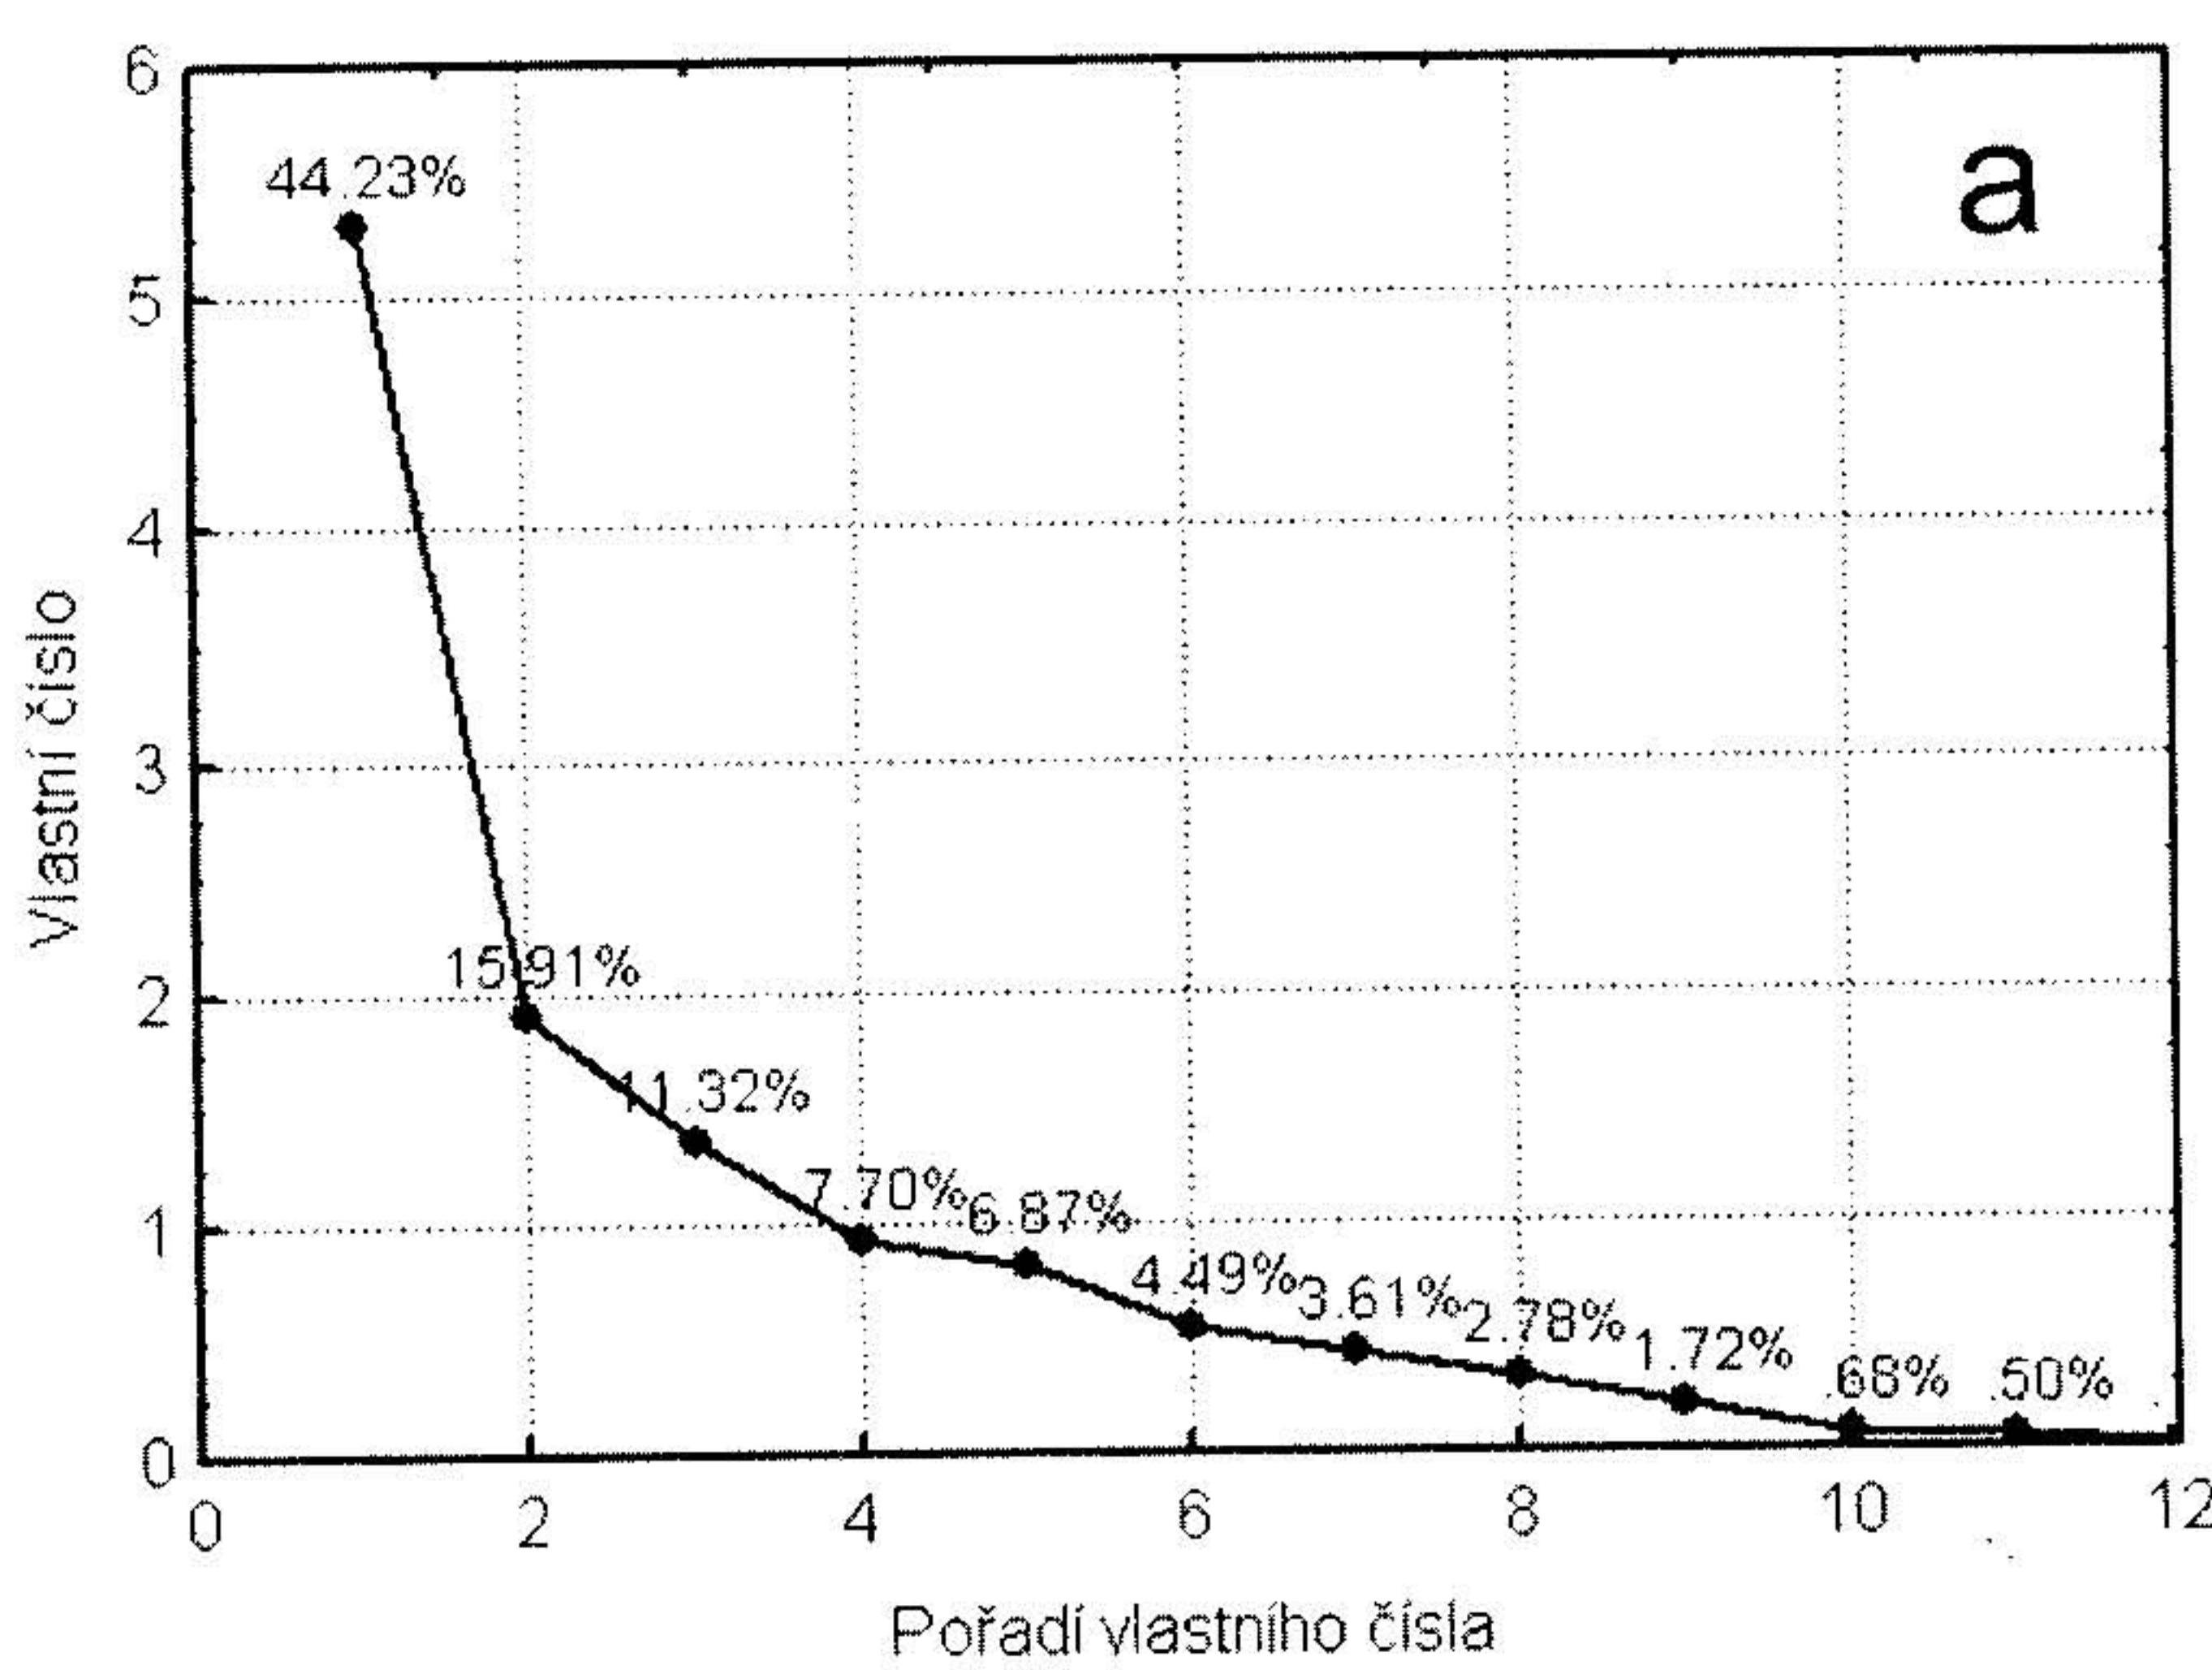
**Data:** Ukazatele kvality vody jsou zastoupeny těmito znaky (viz tab. 1): **BSK5** značí biochemickou spotřebu kyslíku, stanovenou jodometrickou titrací a vyjádřenou v mg O<sub>2</sub>/l a odhad její nejistoty stanovení byl 15 %. Metoda zjišťuje úbytek kyslíku spotřebovaný mikroorganismy při aerobním rozkladu organických látok obsažených ve vodě a slouží proto k nepřímému odhadu množství aerobně rozložitelných organických látok ve vodě. **Ca** značí koncentraci vápníku v mg/l metodou AAS s nejistotou 5 %. **Cl** značí koncentraci chloridů v mg/l metodou iontové chromatografie s nejistotou 10 %. **CHSKCr** značí chemickou spotřebu kyslíku titrací dichromanem draselným a vyjádřenou v mg O<sub>2</sub>/l s nejistotou 15 %. **CHSKMn** značí chemickou spotřebu kyslíku titrací manganistinem draselným a vyjádřenou v mg O<sub>2</sub>/l s nejistotou 15 %. **m** značí neutralizační kapacitu do pH 4,5, která se určuje titrací kyselinou chlorovodíkovou a je vyjádřena v mmol H<sup>+</sup>/l s nejistotou 5 %. **Mg** značí koncentraci hořčíku v mg/l metodou AAS s nejistotou 5 %. **NH4** značí koncentraci amonných iontů v mg/l fotometricky s nejistotou 30 %. **NO3** značí koncentraci dusičnanů v mg/l metodou iontové chromatografie s nejistotou 10 %. **pH** značí hodnotu korigovanou na teplotu 20 °C s nejistotou 5 %. **RL** značí obsah rozpuštěných látok ve vodě v mg/l gravimetricky s nejistotou 10 %. **SO4** značí koncentraci síranů v mg/l metodou iontové chromatografie s nejistotou 10 %.

**Řešení:** Byly užity programy NCSS2000 a STATISTICA. Cattelův indexový graf vlastních čísel u PCA na obr. 1a ukazuje, že první faktor vysvětuje 44 %, dále první dva faktory 60 % a první tři faktory 72 % variability dat. z grafu vlastních čísel vyplývá, že 3 faktory jsou zde statisticky významné. Z grafu komponentních vah prvních dvou komponent (obr. 1b) je vidět, že žádná z původních proměnných není faktorově čistá, ale je kombinací dvou faktorů.

Znaky tvoří čtyři shluky, což značí, že mezi ukazateli existuje nějaký vztah. První shluk na obrázku 2 zdola nahoru je tvořen metodami **BSK5**, **CHSKCr** a **CHSKMn**, druhý shluk je tvořen **m** a **pH**, třetí shluk je tvořen **Cl**, **RL**, **Ca**, **SO4**, **Mg** a **NO3**, a konečně

**Tab. 1. Zdrojová matice dat 12 ukazatelů kvality vody Vltavy v období od 20. 5. 1996 do 20. 6. 1997.**

ID	Objekt	BSK5	Ca	Cl	CHSKCr	CHSKMn	m	Mg	NH <sub>4</sub>	NO <sub>3</sub>	pH	RL	SO <sub>4</sub>
		[mg/l]	[mg/l]	[mg/l]	[mg/l]	[mg/l]	[mmol/l]	[mg/l]	[mg/l]	[mg/l]	[-]	[mg/l]	[mg/l]
1	101	5.5	17.2	9.7	46	9.2	0.6	5	0.39	14	7.5	174	41.3
2	102	5.1	16.4	8.6	30	10.6	0.74	4.4	0.62	11	7.6	163	32.2
3	103	6	16	8.3	25	7.3	0.74	4.13	0.4	7.1	7.6	134	24.5
4	104	6	17	8	20	7.8	0.86	4.3	0.45	5	7.4	152	23
5	105	3.8	16	7.9	34	8.7	0.92	4	0.7	6	7.5	138	35
6	106	14	17.5	8.8	52	14	1	4.5	0.3	5.7	7.6	134	27
7	107	2.4	21	8.3	16	8.2	0.94	6.3	0.7	12.1	7.4	166	30
8	108	9	19.5	12.4	23	11	1	5.7	0.9	17	7.4	164	39.5
9	109	5.5	19.5	11.5	24	7.9	0.68	5.8	0.95	13.7	7.5	131	39
10	110	4	15	7.2	19	8.4	0.88	4.3	1.2	5.2	7.3	133	29
11	201	2.6	18.4	10.2	15	8.9	0.61	5.6	0.45	14	7.4	193	45.8
12	202	3.6	17	9.1	27	9	0.82	4.5	1.19	7.4	7.2	169	36.1
13	203	2.8	17	8.6	24	7	0.84	4.7	0.45	7	7.4	180	29
14	204	4.2	17.5	8.1	21	7.1	0.94	4.6	1.1	4.8	7.1	168	26
15	205	4.4	18	11	24	6.7	1.05	5	0.55	6	7.3	166	44
16	206	3.8	19	10	19	11	1	5.4	1.2	4.9	7.4	138	35.5
17	207	3.2	22	8.6	29	9.7	1	6.8	0.75	12.5	7.3	155	28
18	208	4.6	20	11.7	23	7.2	0.94	5.9	0.7	12.2	7.3	154	44.5
19	209	4.2	16.5	8.1	22	7.1	0.7	4.9	0.65	8.3	7.6	119	32.5
20	210	3.8	15.5	8.4	21	7.2	0.72	4.4	1.2	6.4	7.2	121	32.5
21	401	5.8	18.5	10.3	27	10.9	0.62	5.3	0.44	13.8	7.3	176	44.4
22	402	5	17.6	10.1	25	9.9	0.85	4.7	0.74	8	7.4	171	35.7
23	403	3.8	20	10.6	31	8.6	0.94	5.7	0.5	8.7	7.4	174	35.5
24	404	4.4	20	10.4	25	7.9	1	5.6	0.35	6	7.3	174	29
25	406	6	21	12.2	29	10	1.1	5.7	0.35	5.1	7.5	147	35
26	407	3.4	23	11.3	29	9.7	1.05	7.2	0.85	15.6	7.5	189	31.5
27	408	7.5	23	15.5	22	6.8	0.92	6.5	0.6	15.5	7.5	167	48.5
28	409	7	16	8.4	28	6.8	0.72	4.8	0.8	9.6	7.7	133	27
29	410	4.6	15	8.5	24	5.8	0.82	4.5	0.8	6.3	7.4	129	28.5
30	501	4.3	19.3	10.4	25	12.3	0.6	5.5	0.49	13.8	7.5	181	44.4
31	502	5.1	19	10.9	24	10.1	0.84	5	0.62	8.2	7.4	170	36.7
32	503	4.6	21	11.3	36	9.1	1.05	5.8	0.5	8.8	7.5	173	36.5
33	504	6.5	20	10.7	24	8.6	1	5.7	0.75	5.9	7.3	183	29
34	505	7	21	14	32	9.4	1.3	5.7	0.8	6	7.5	173	42
35	508	7.5	21	15.8	22	7.5	0.94	6.3	0.6	15.8	7.6	169	50
36	509	4.4	19.5	10.9	26	8.6	0.72	5.8	0.65	12.5	7.6	139	37.5
37	510	4.4	15	8.5	26	7.5	0.78	4.5	0.9	6.4	7.2	130	28.5
38	701	5.2	18.1	11.5	35	12.5	0.55	4.9	0.53	13.6	7.5	186	44.1
39	702	8.5	22.2	17.7	36	13.2	1.12	6.3	0.36	9.5	7.9	204	40.5
40	703	6	24	13.6	37	12	1.05	6.8	0.65	10	7.6	204	41.5
41	704	6.5	25	14.7	31	10	1.3	7.5	0.15	7.7	7.6	220	34
42	705	6	24	19	43	11	1.5	6.9	0.35	7.5	7.9	207	45
43	706	9	23	16.4	47	13	1.3	6.4	0.45	7	7.6	185	33.5
44	707	3	26	14	27	9.4	1.1	8	0.8	18.4	7.6	220	35
45	708	8.5	24	21.5	43	11	1.1	7.5	0.7	23.5	7.5	201	53
46	709	7	22	14.3	38	7	0.76	6.6	0.8	17.3	7.8	141	44
47	710	3	24	17.3	32								

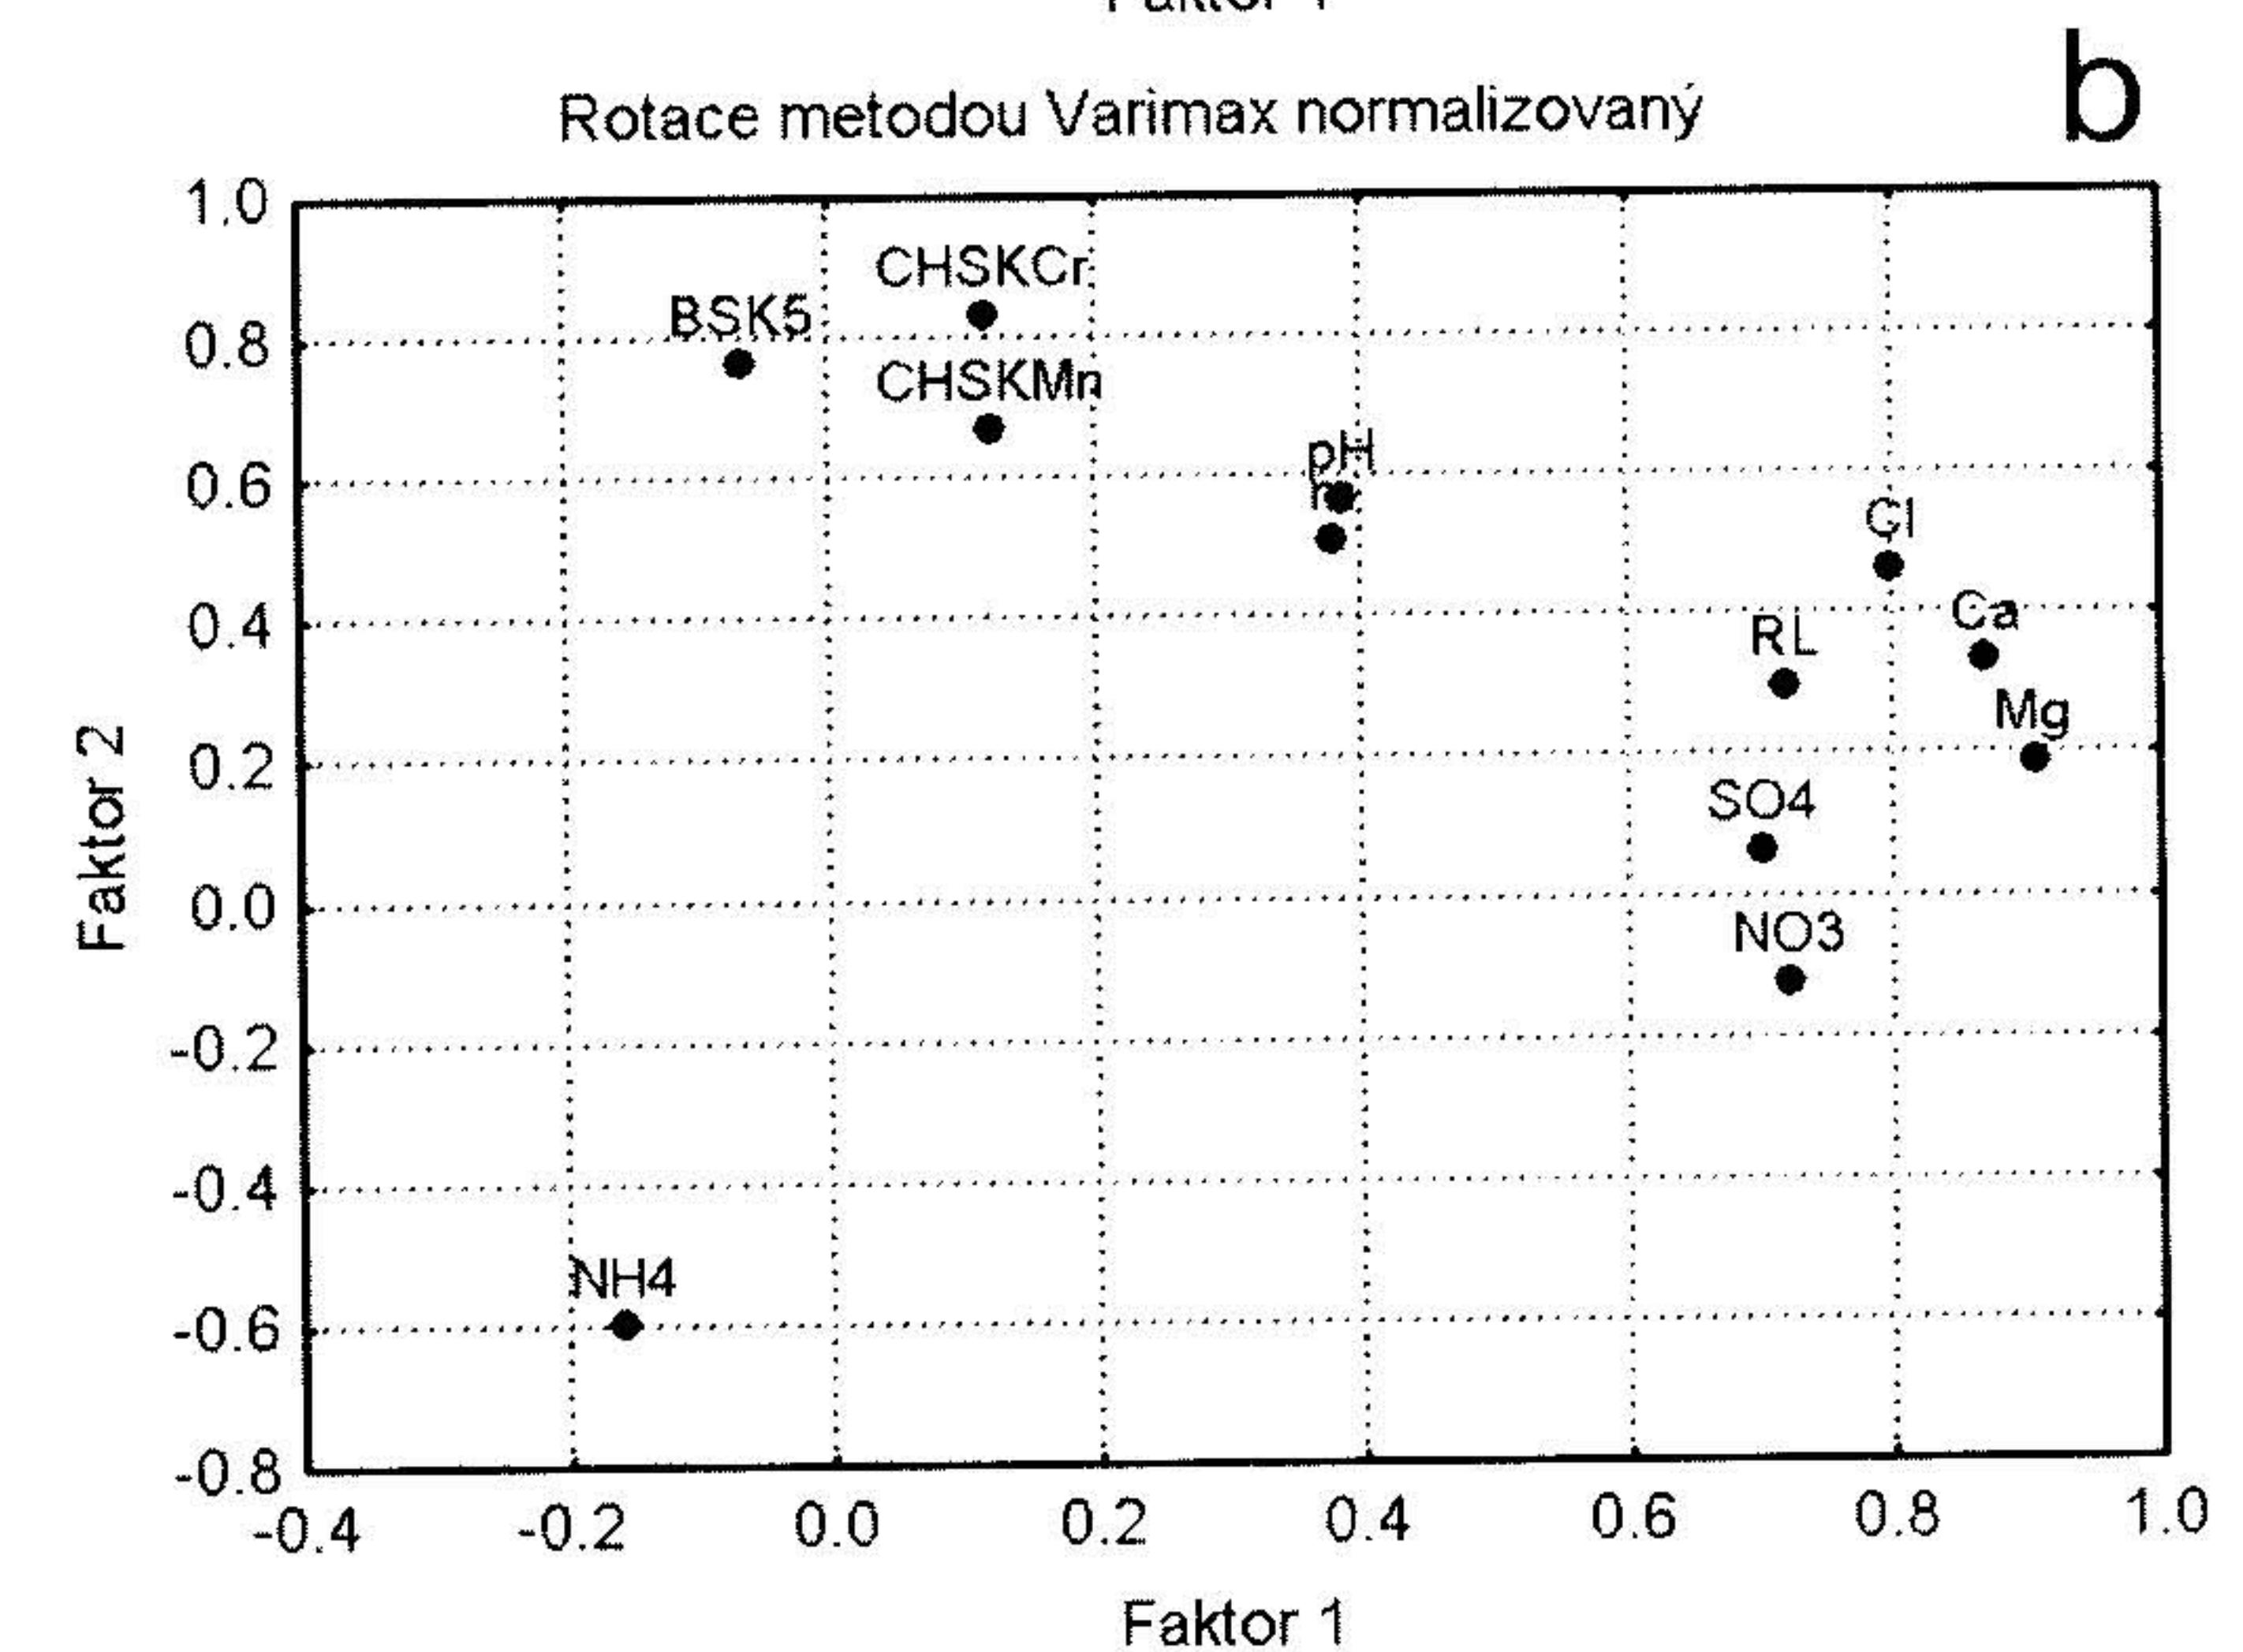
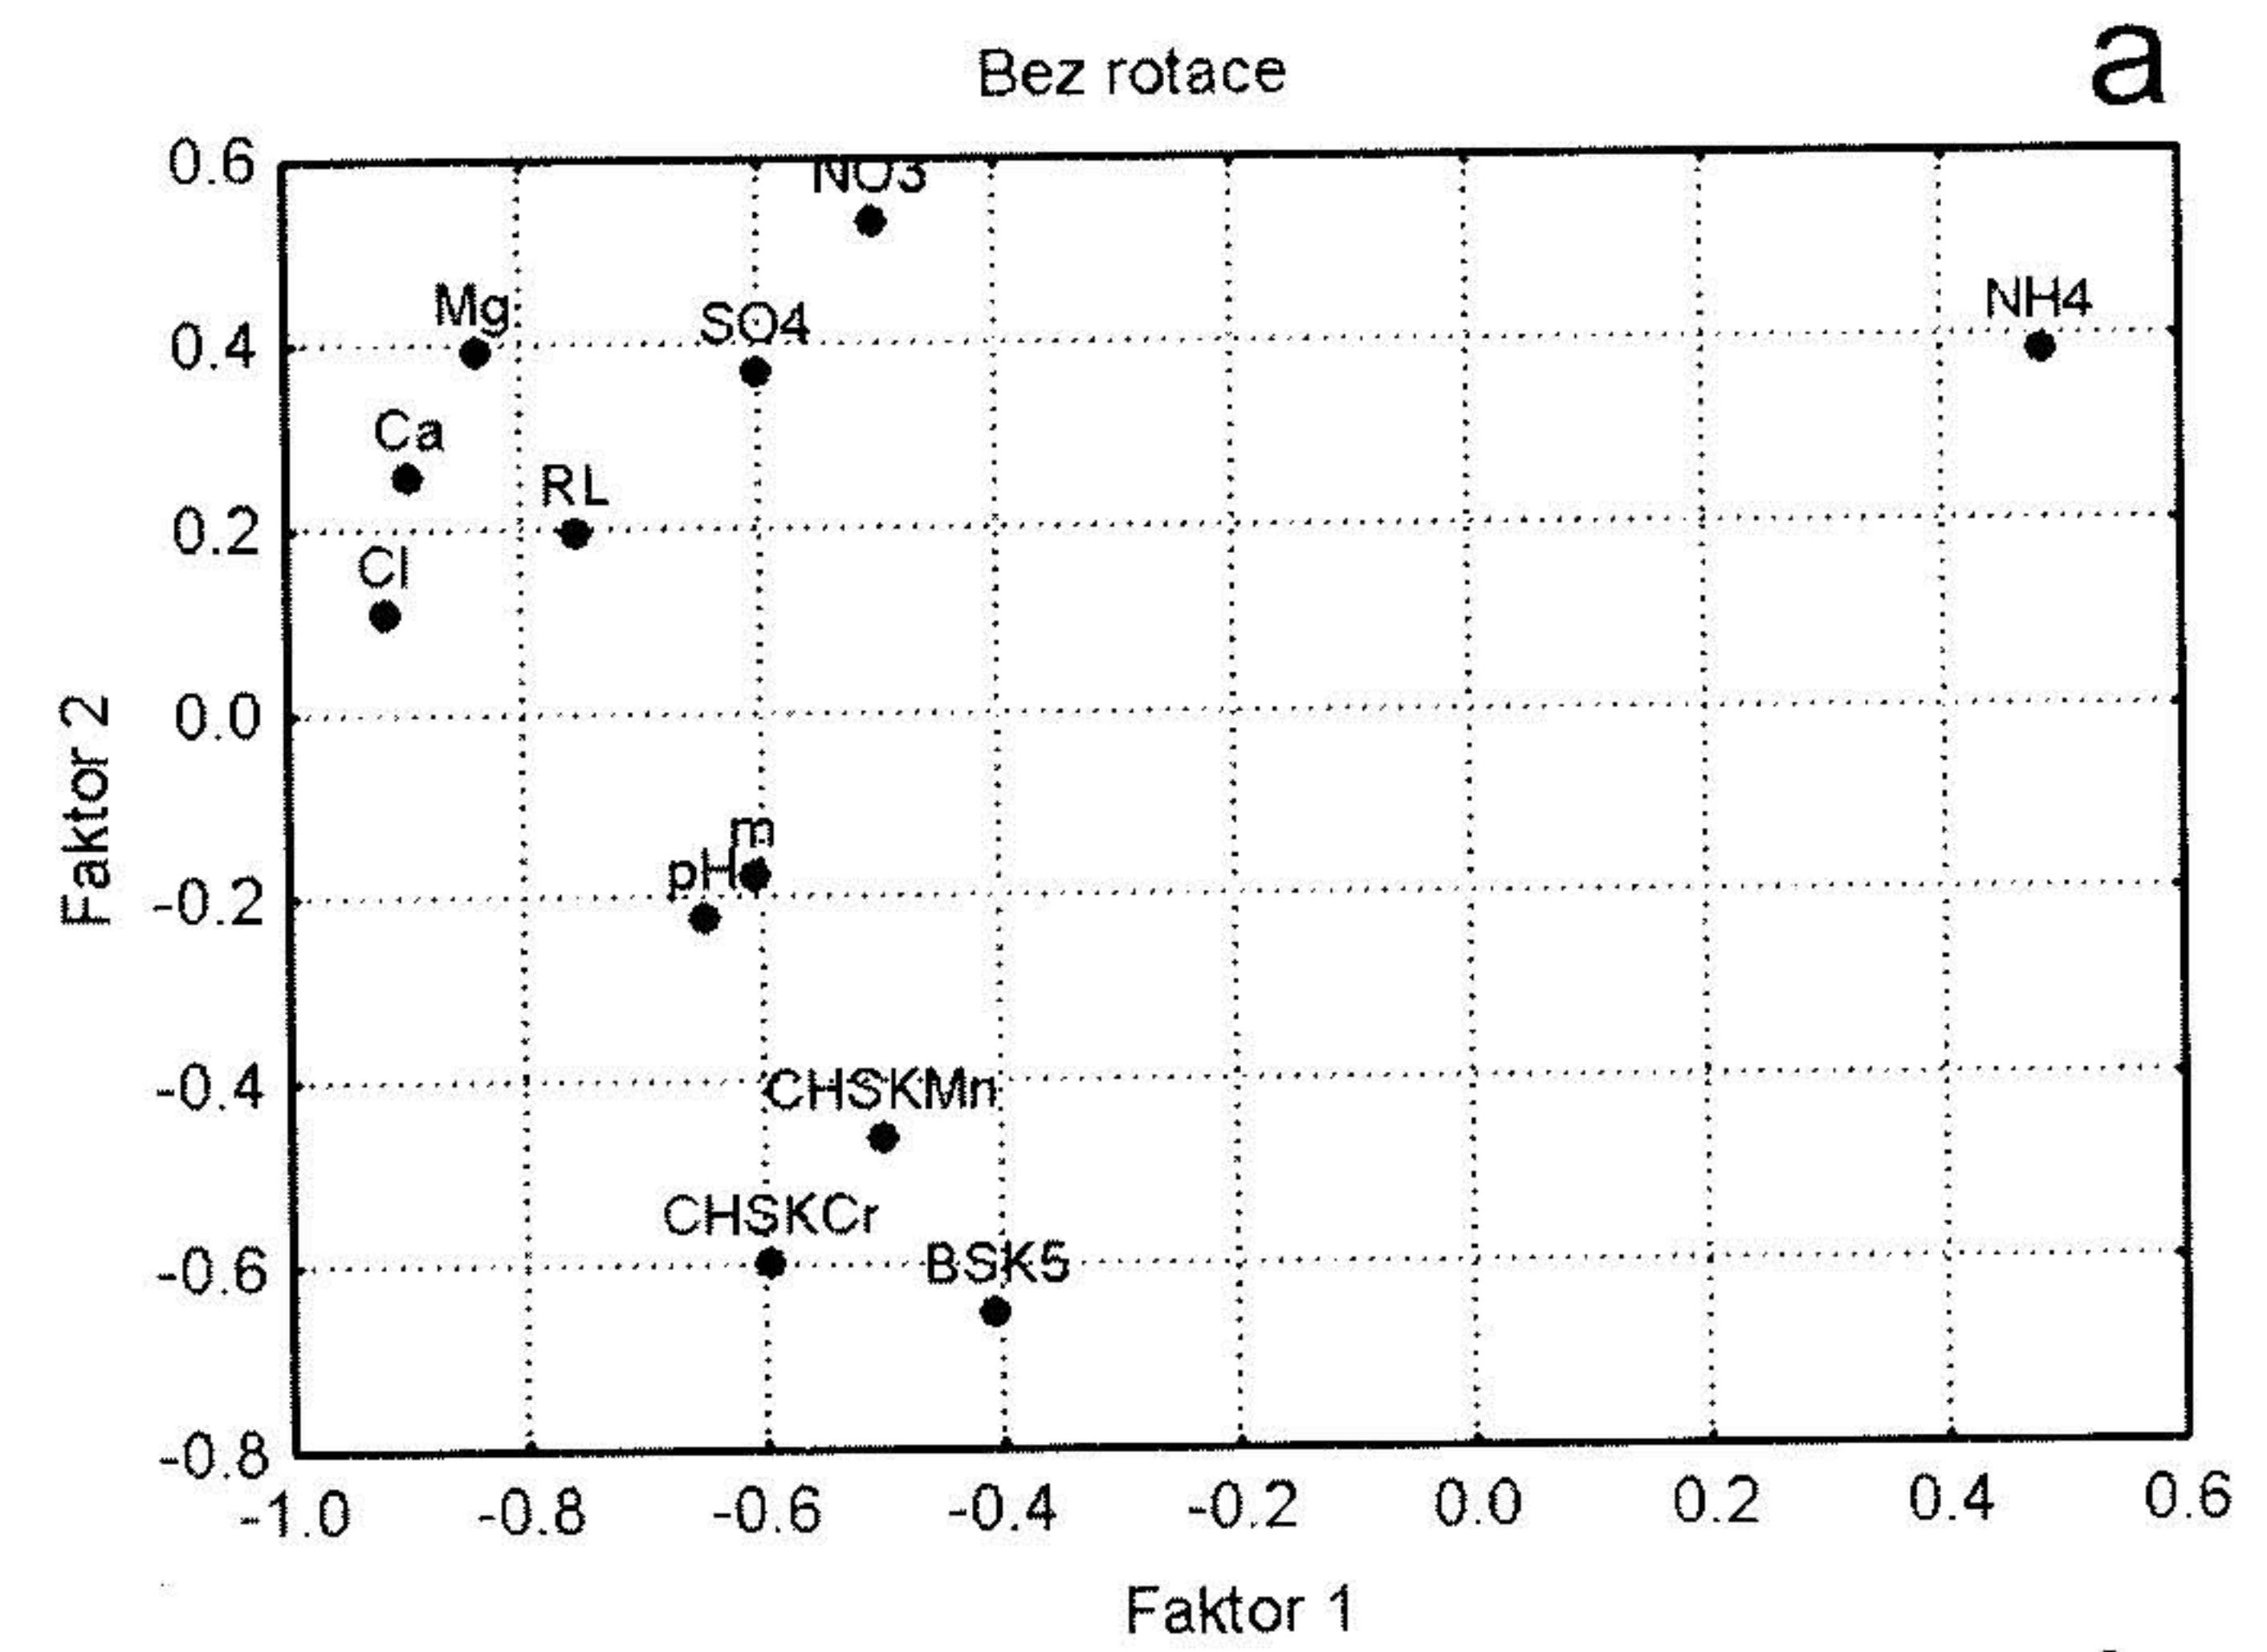


Obr. 1. Grafy metody hlavních komponent obsahují (a) Cattelův indexový graf vlastních čísel, který zde ukazuje na 3 hlavní komponenty, a (b) graf komponentních vah pro první dvě hlavní komponenty.

tů. Graf 1-2 na obr. 1 indikuje shluk, týkající se místa 7 v různých měsících roku. Také zbývající dva grafy odhalují odlehlejší objekty, trendy a podobné objekty umístěné blízko sebe. Daleko od počátku obou komponentních os se nalézají extrémy. Izolované objekty mohou být i odlehlymi objekty, které jsou silně nepodobné ostatním objektům. Umístění objektů na ploše obou latentních hlavních komponent může být porovnáváno s komponentními vahami původních znaků a vysvětleno tak, že první komponenta se týká spíše anorganických iontů zatímco druhá komponenta spíše organických látek.

Dendrogram 47 objektů váženým průměrem dvojic na obr. 4 indikuje na 4 shluky. Druhý shluk objektů 707, 704, 708, 705, 710, 703, 702 je patrný i v levé části obrázku 3a, i když oba jsou vypočteny rozlišnou matematickou technikou, a to u PCA z korelace a u dendrogramu z podobnosti objektů. I ostatní shluky lze porovnat s rozmištěním objektů v grafech komponentního skóre na obr. 3.

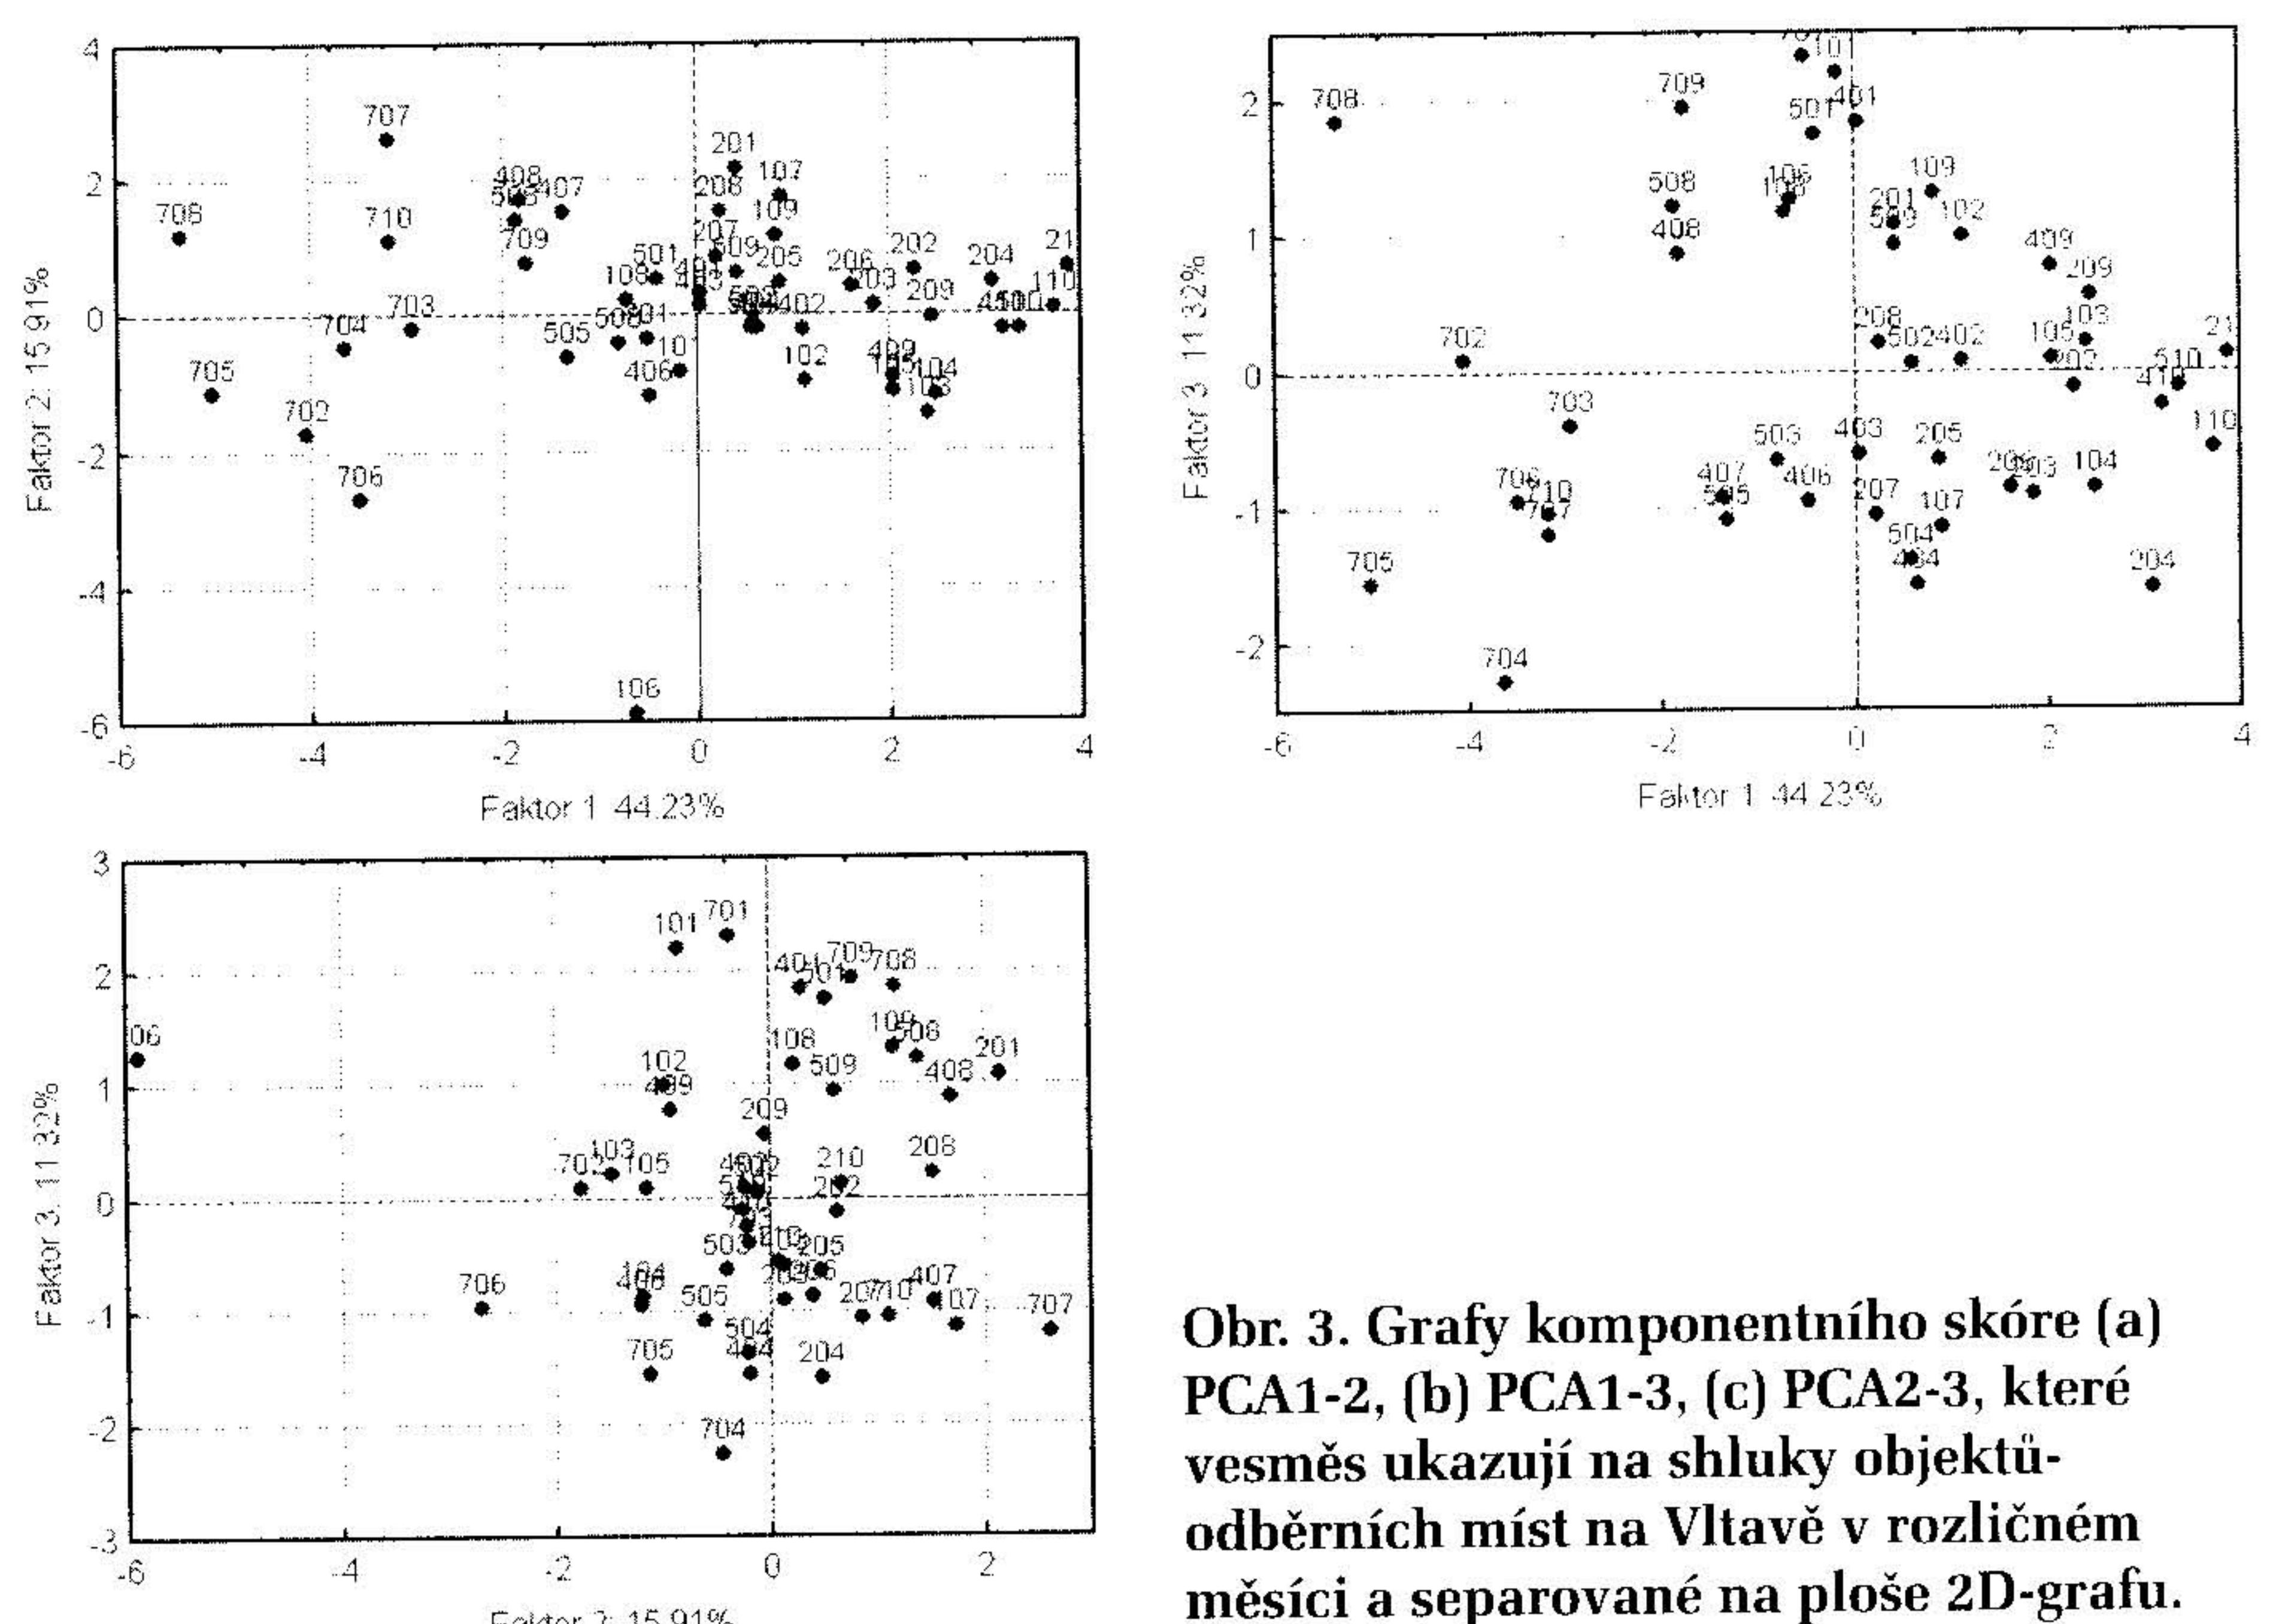
Vícerozměrné škálování objektů je technika vytvoření subjektivní mapy relativního rozmištění objektů (nebo znaků) v rovině dvojrozměrného grafu na základě podobnosti mezi objekty, tzv. *matice proximity*. Vícerozměrným škálováním MDS se ze zadaných vzájemných vzdáleností mezi analyticky-chemickými ukazateli znaků v matici proximit vytváří mapa relativních poloh jednoho znaku vůči druhému (obr. 5, obr. 6). Mapa může obsahovat jednu, dvě nebo maximálně tři souřadnice, i když teoreticky jich může být i více. Řešení může být dvojí, metrické CMDS na základě vzdá-



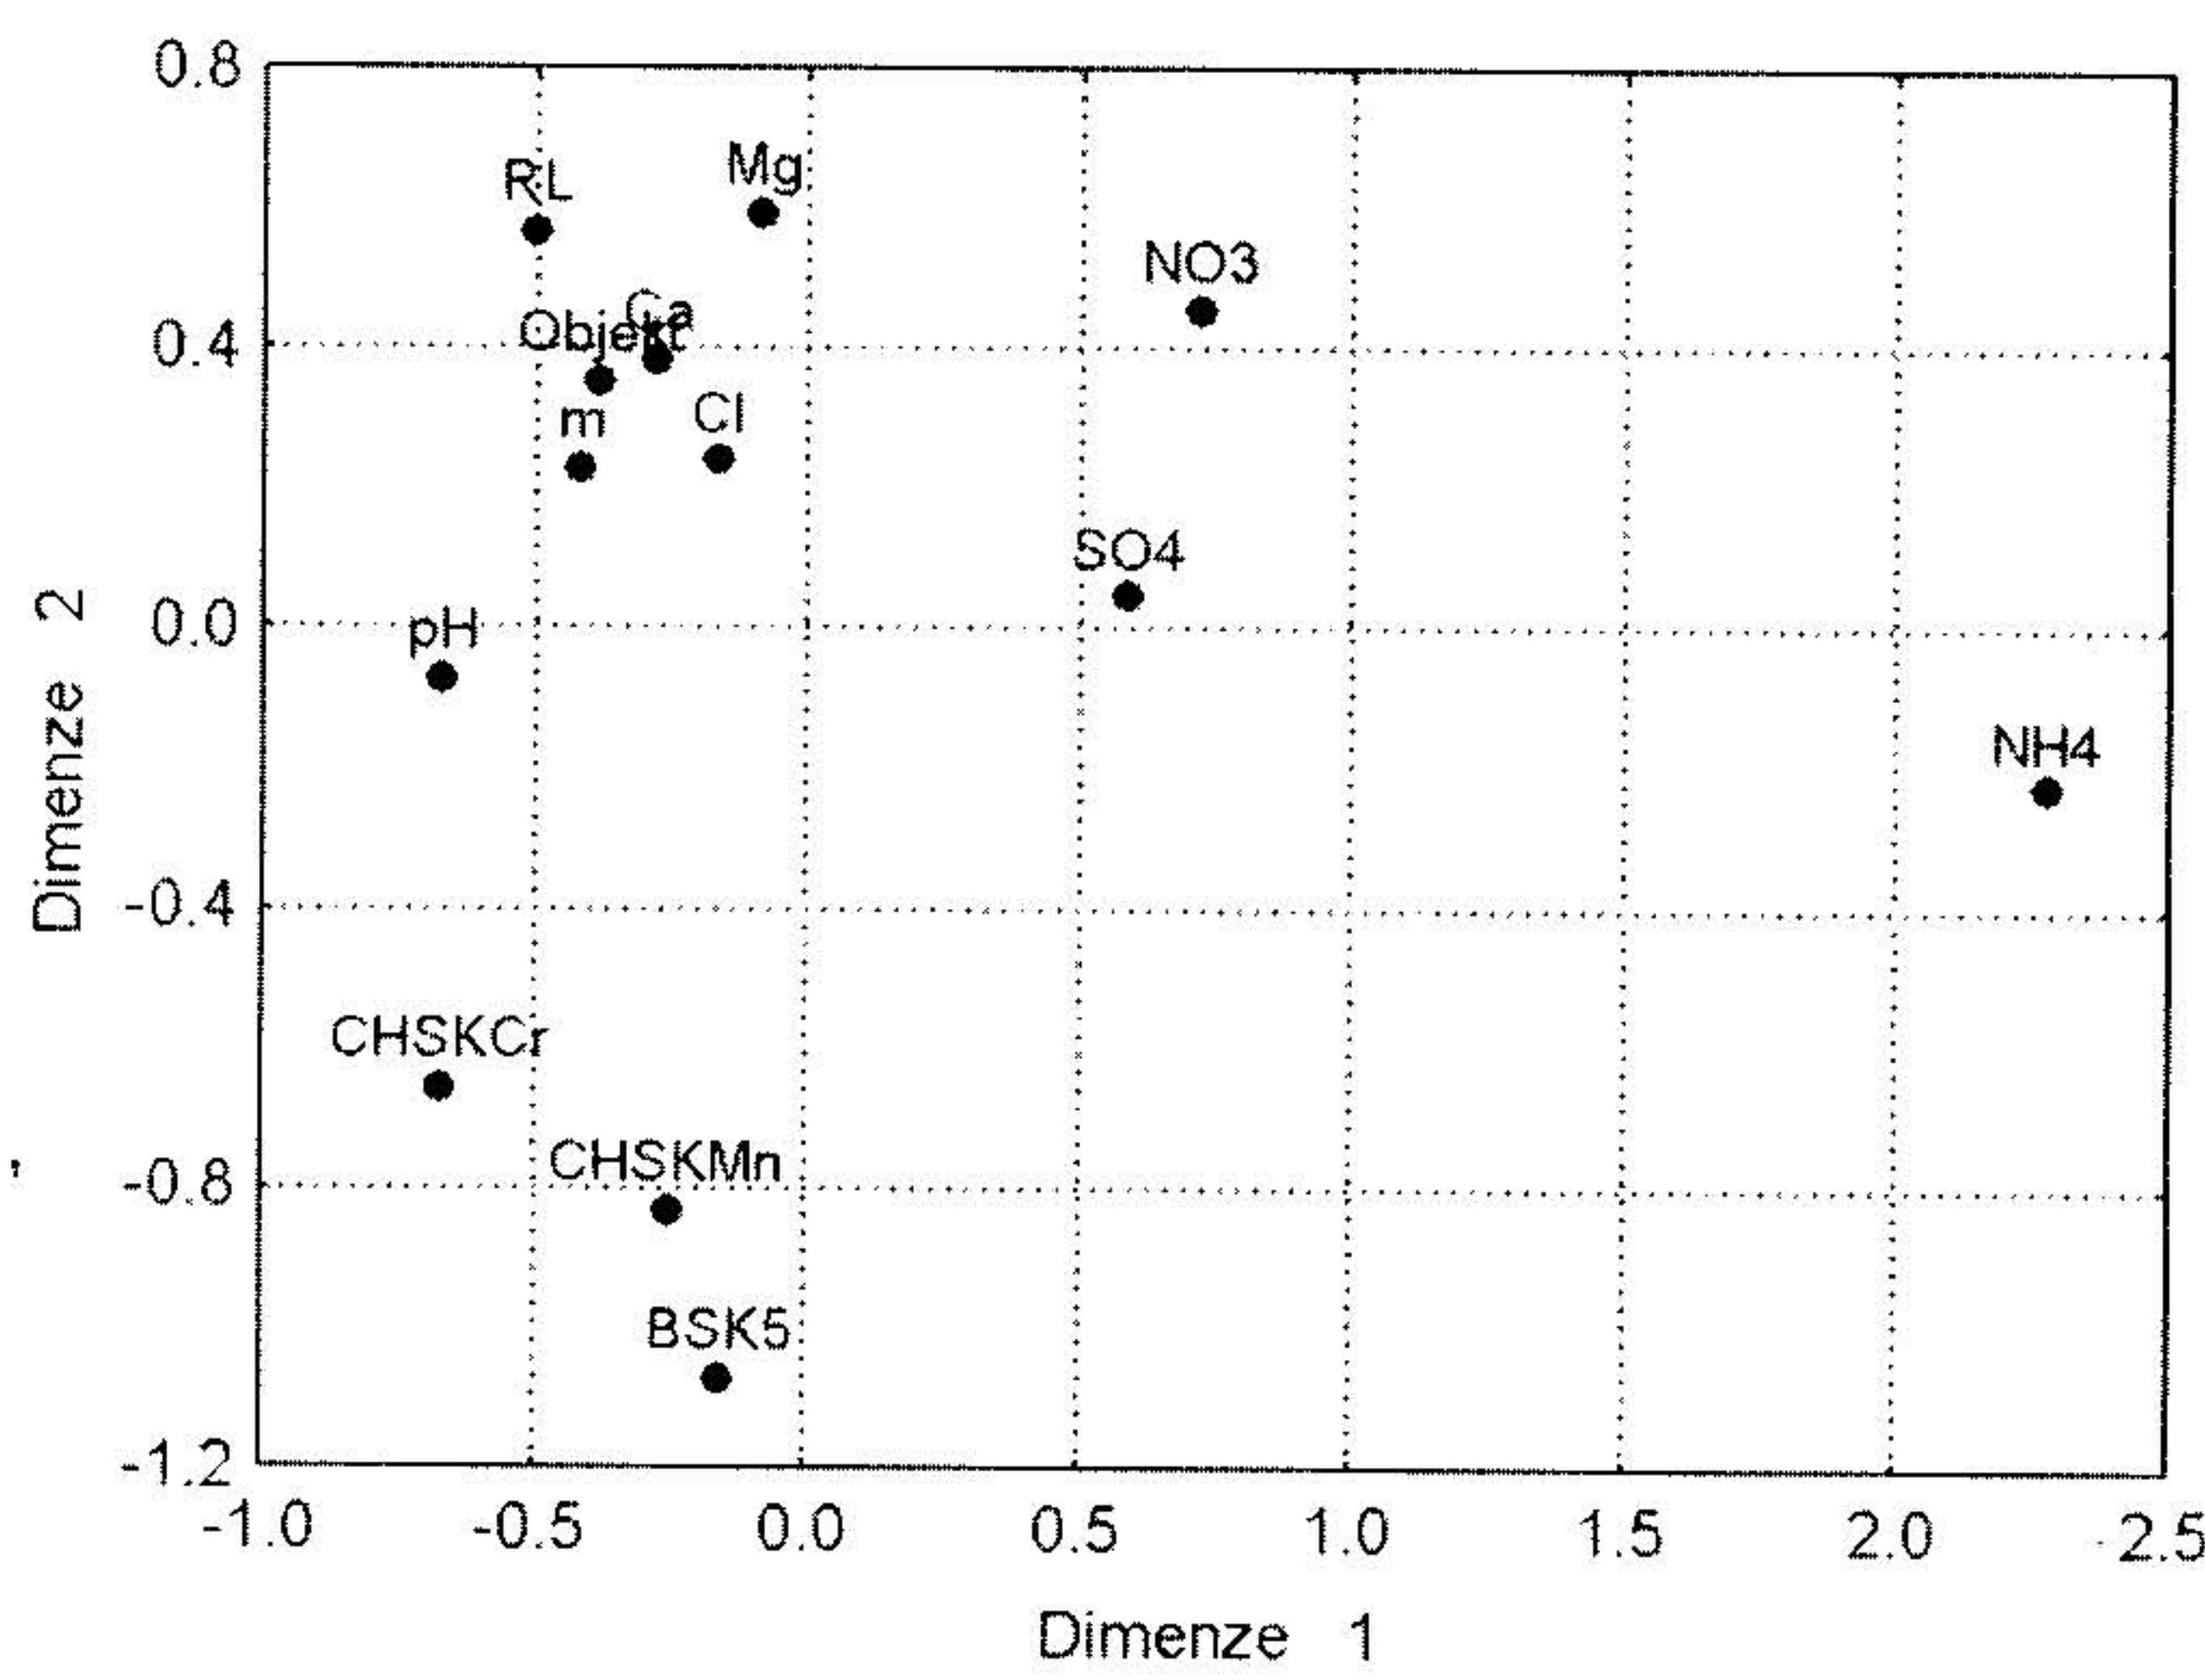
Obr. 2. Mezi grafy faktorové analýzy patří především graf faktorových vah (a) bez předešlé rotace, (b) po předešlé rotaci normalizovanou Varimax metodou, která úspěšně separovala znaky na faktorově čisté.

lenosti mezi analytickymi ukazateli nebo nemetrické NNDS na základě uspořádaných pořadových čísel seřazených vzdáleností mezi těmito analytickymi znaky.

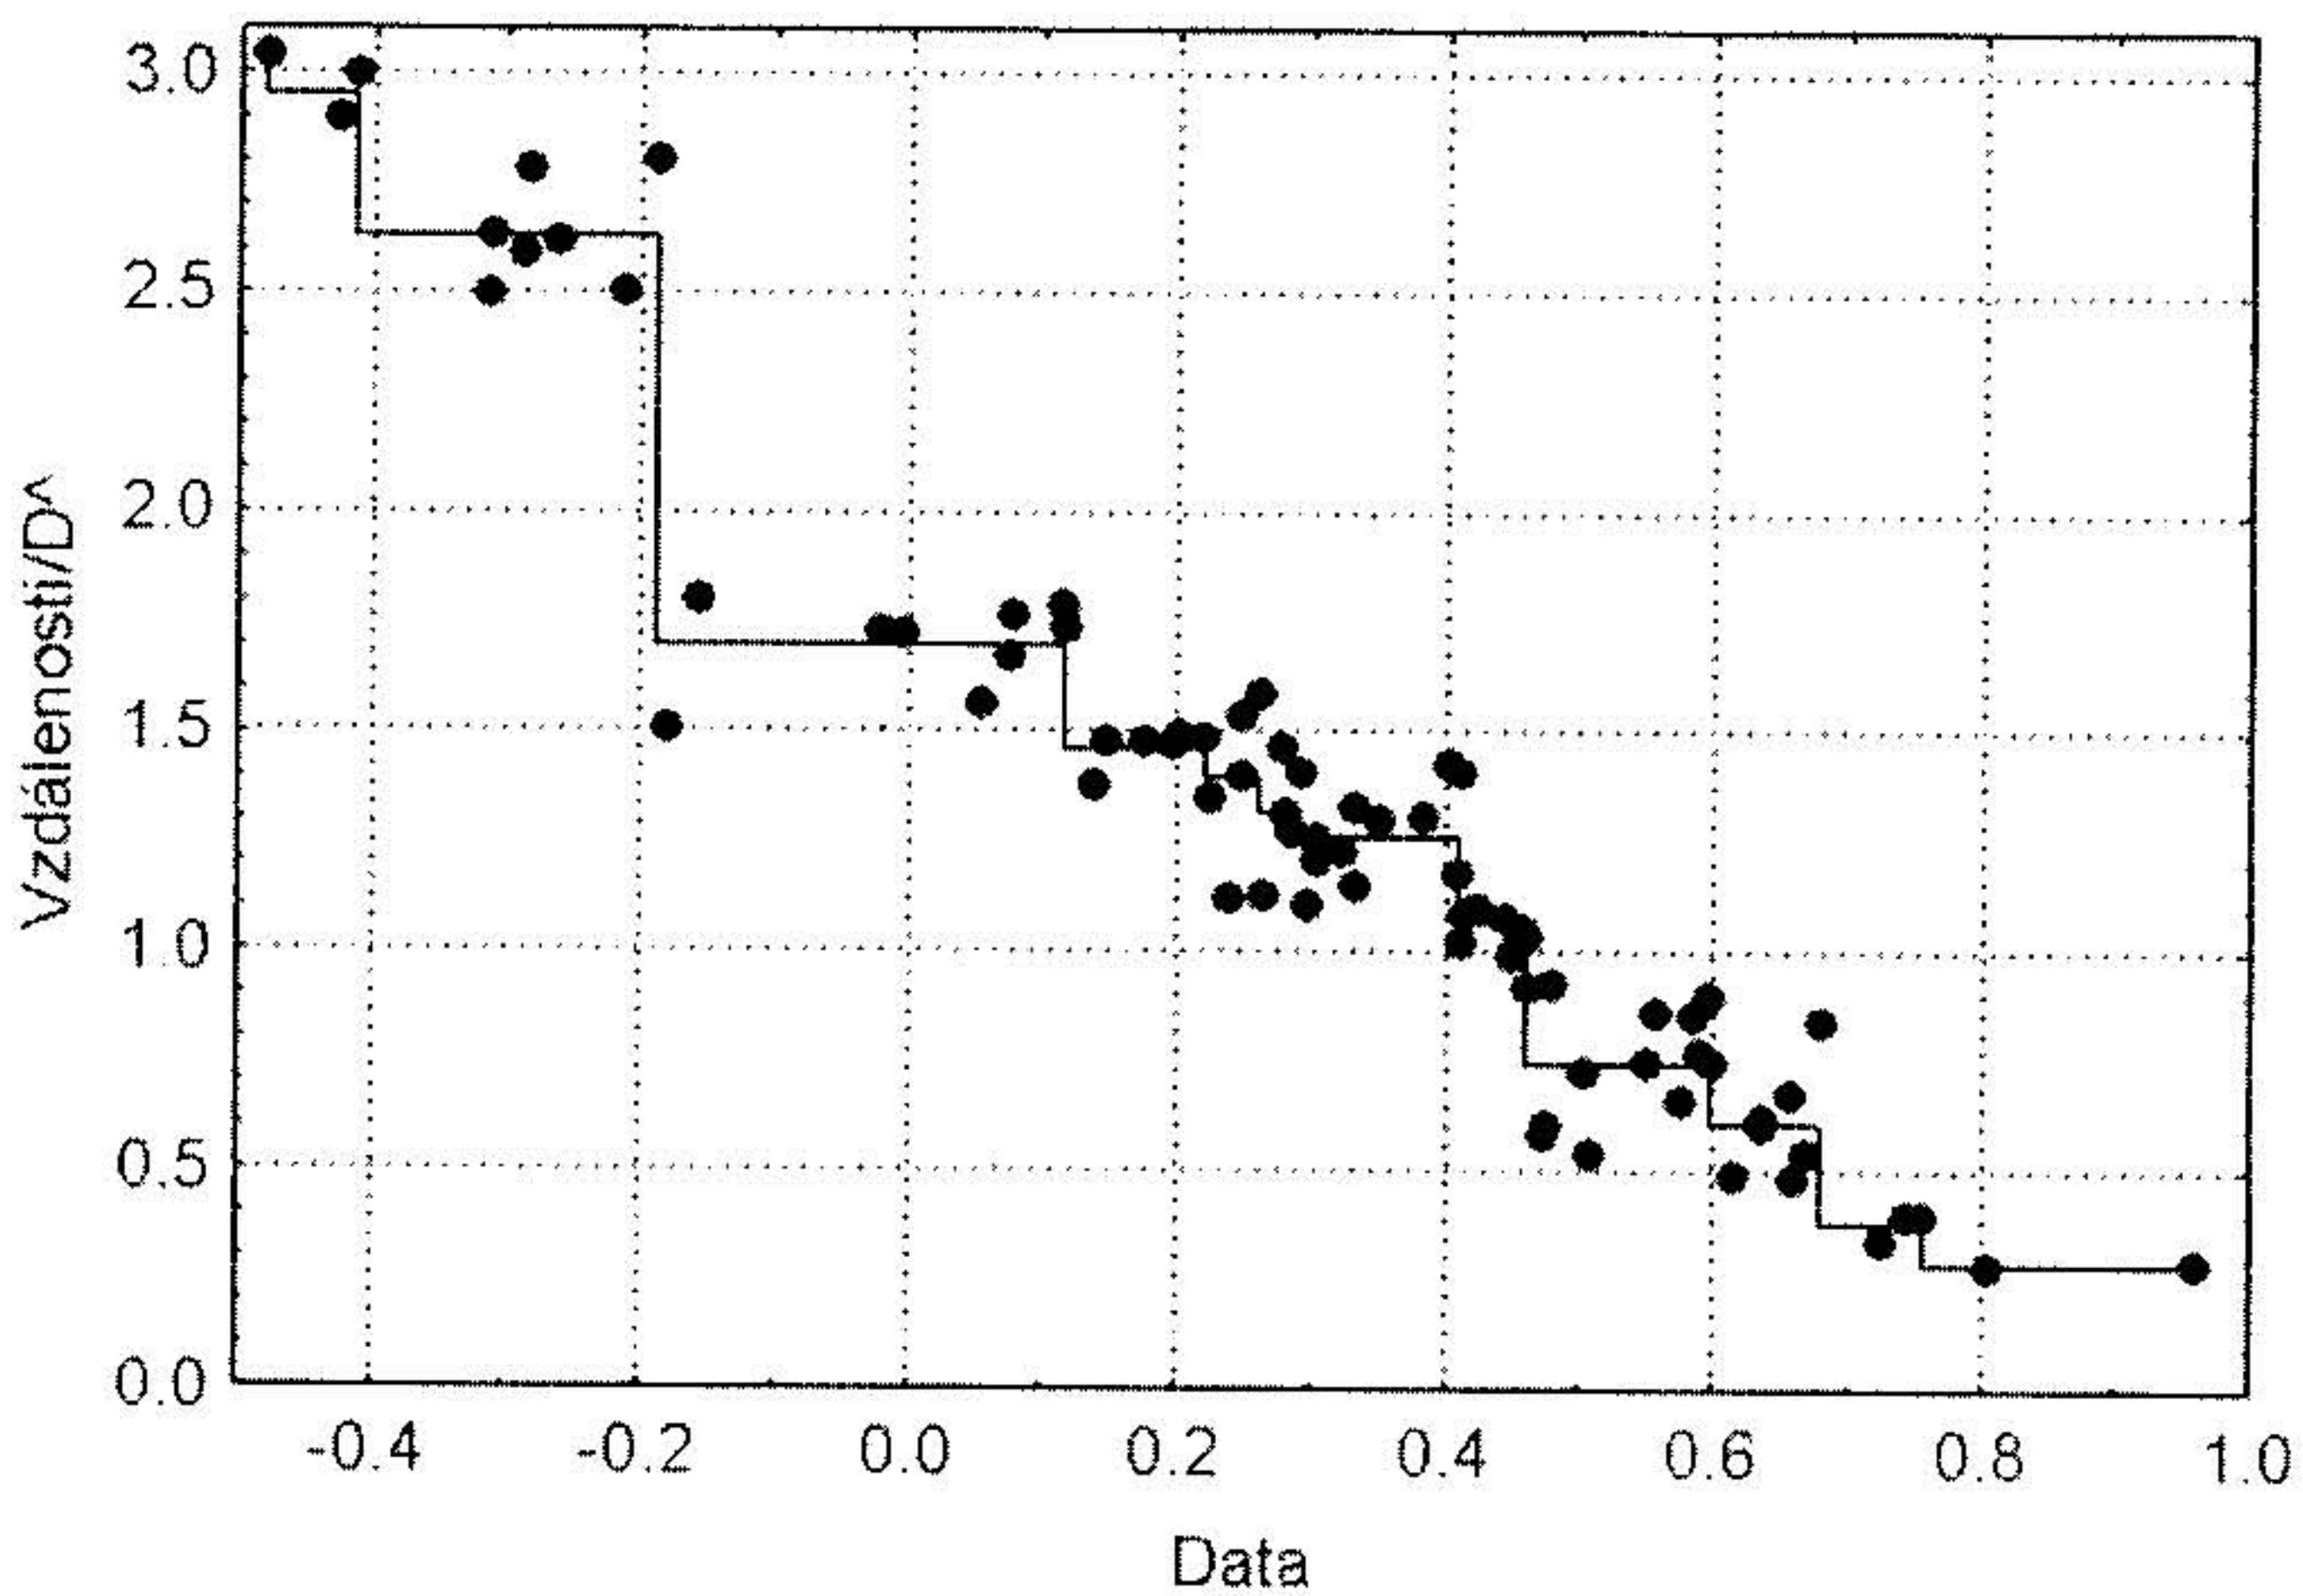
**a) Nalezení počtu souřadnic mapy MDS.** Prvním důležitým úkolem v analýze MDS je určení počtu použitelných souřadnic, ve kterých budeme zobrazovat porovnávané znaky čili analyticky-chemické ukazatele. Každá souřadnice představuje rozličný základní faktor. Je cílem udržet počet těchto použitelných souřadnic pro



Obr. 3. Grafy komponentního skóre (a) PCA1-2, (b) PCA1-3, (c) PCA2-3, které vesměs ukazují na shluky objektů-odběrných míst na Vltavě v rozličném měsíci a separované na ploše 2D-grafu.



Shepardův diagram, ● Vzdálenosti a —  $D^*$  vs. data

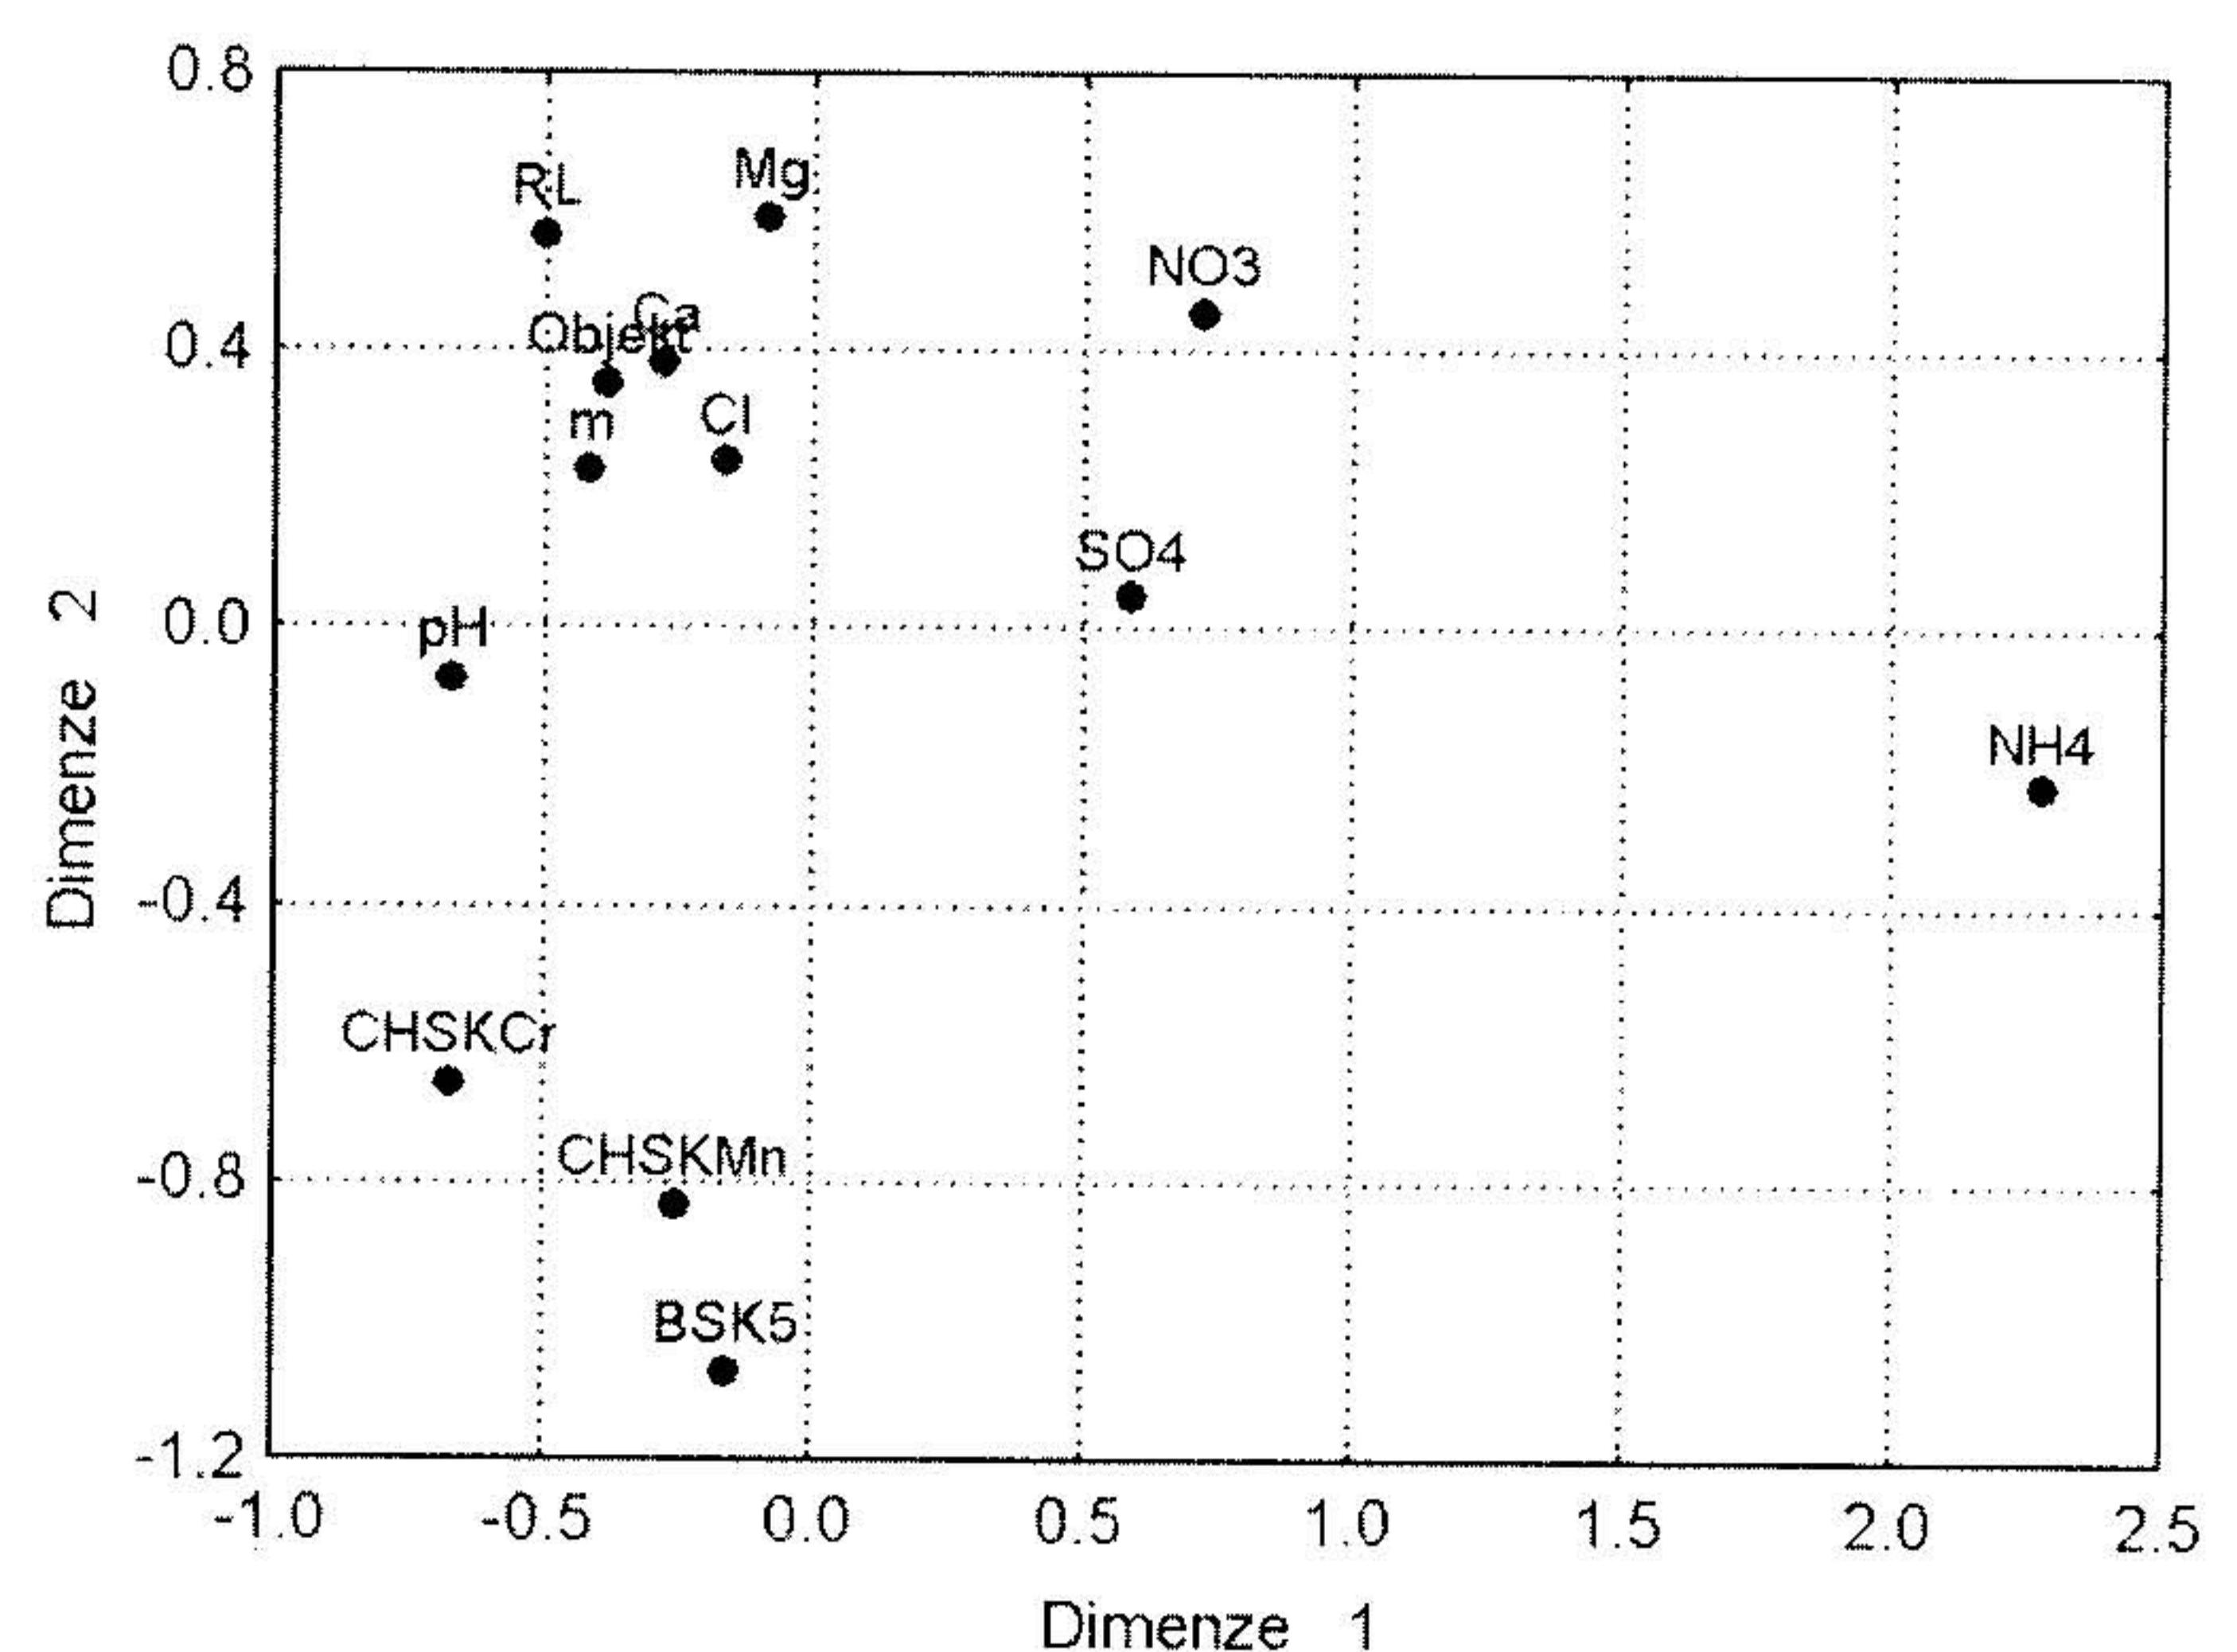


Obr. 4. Dendrogram 47 objektů-odběrných míst na Vltavě v rozličném měsíci metodou váženého průměru dvojic ukazuje na 4 shluky separovaných objektů.

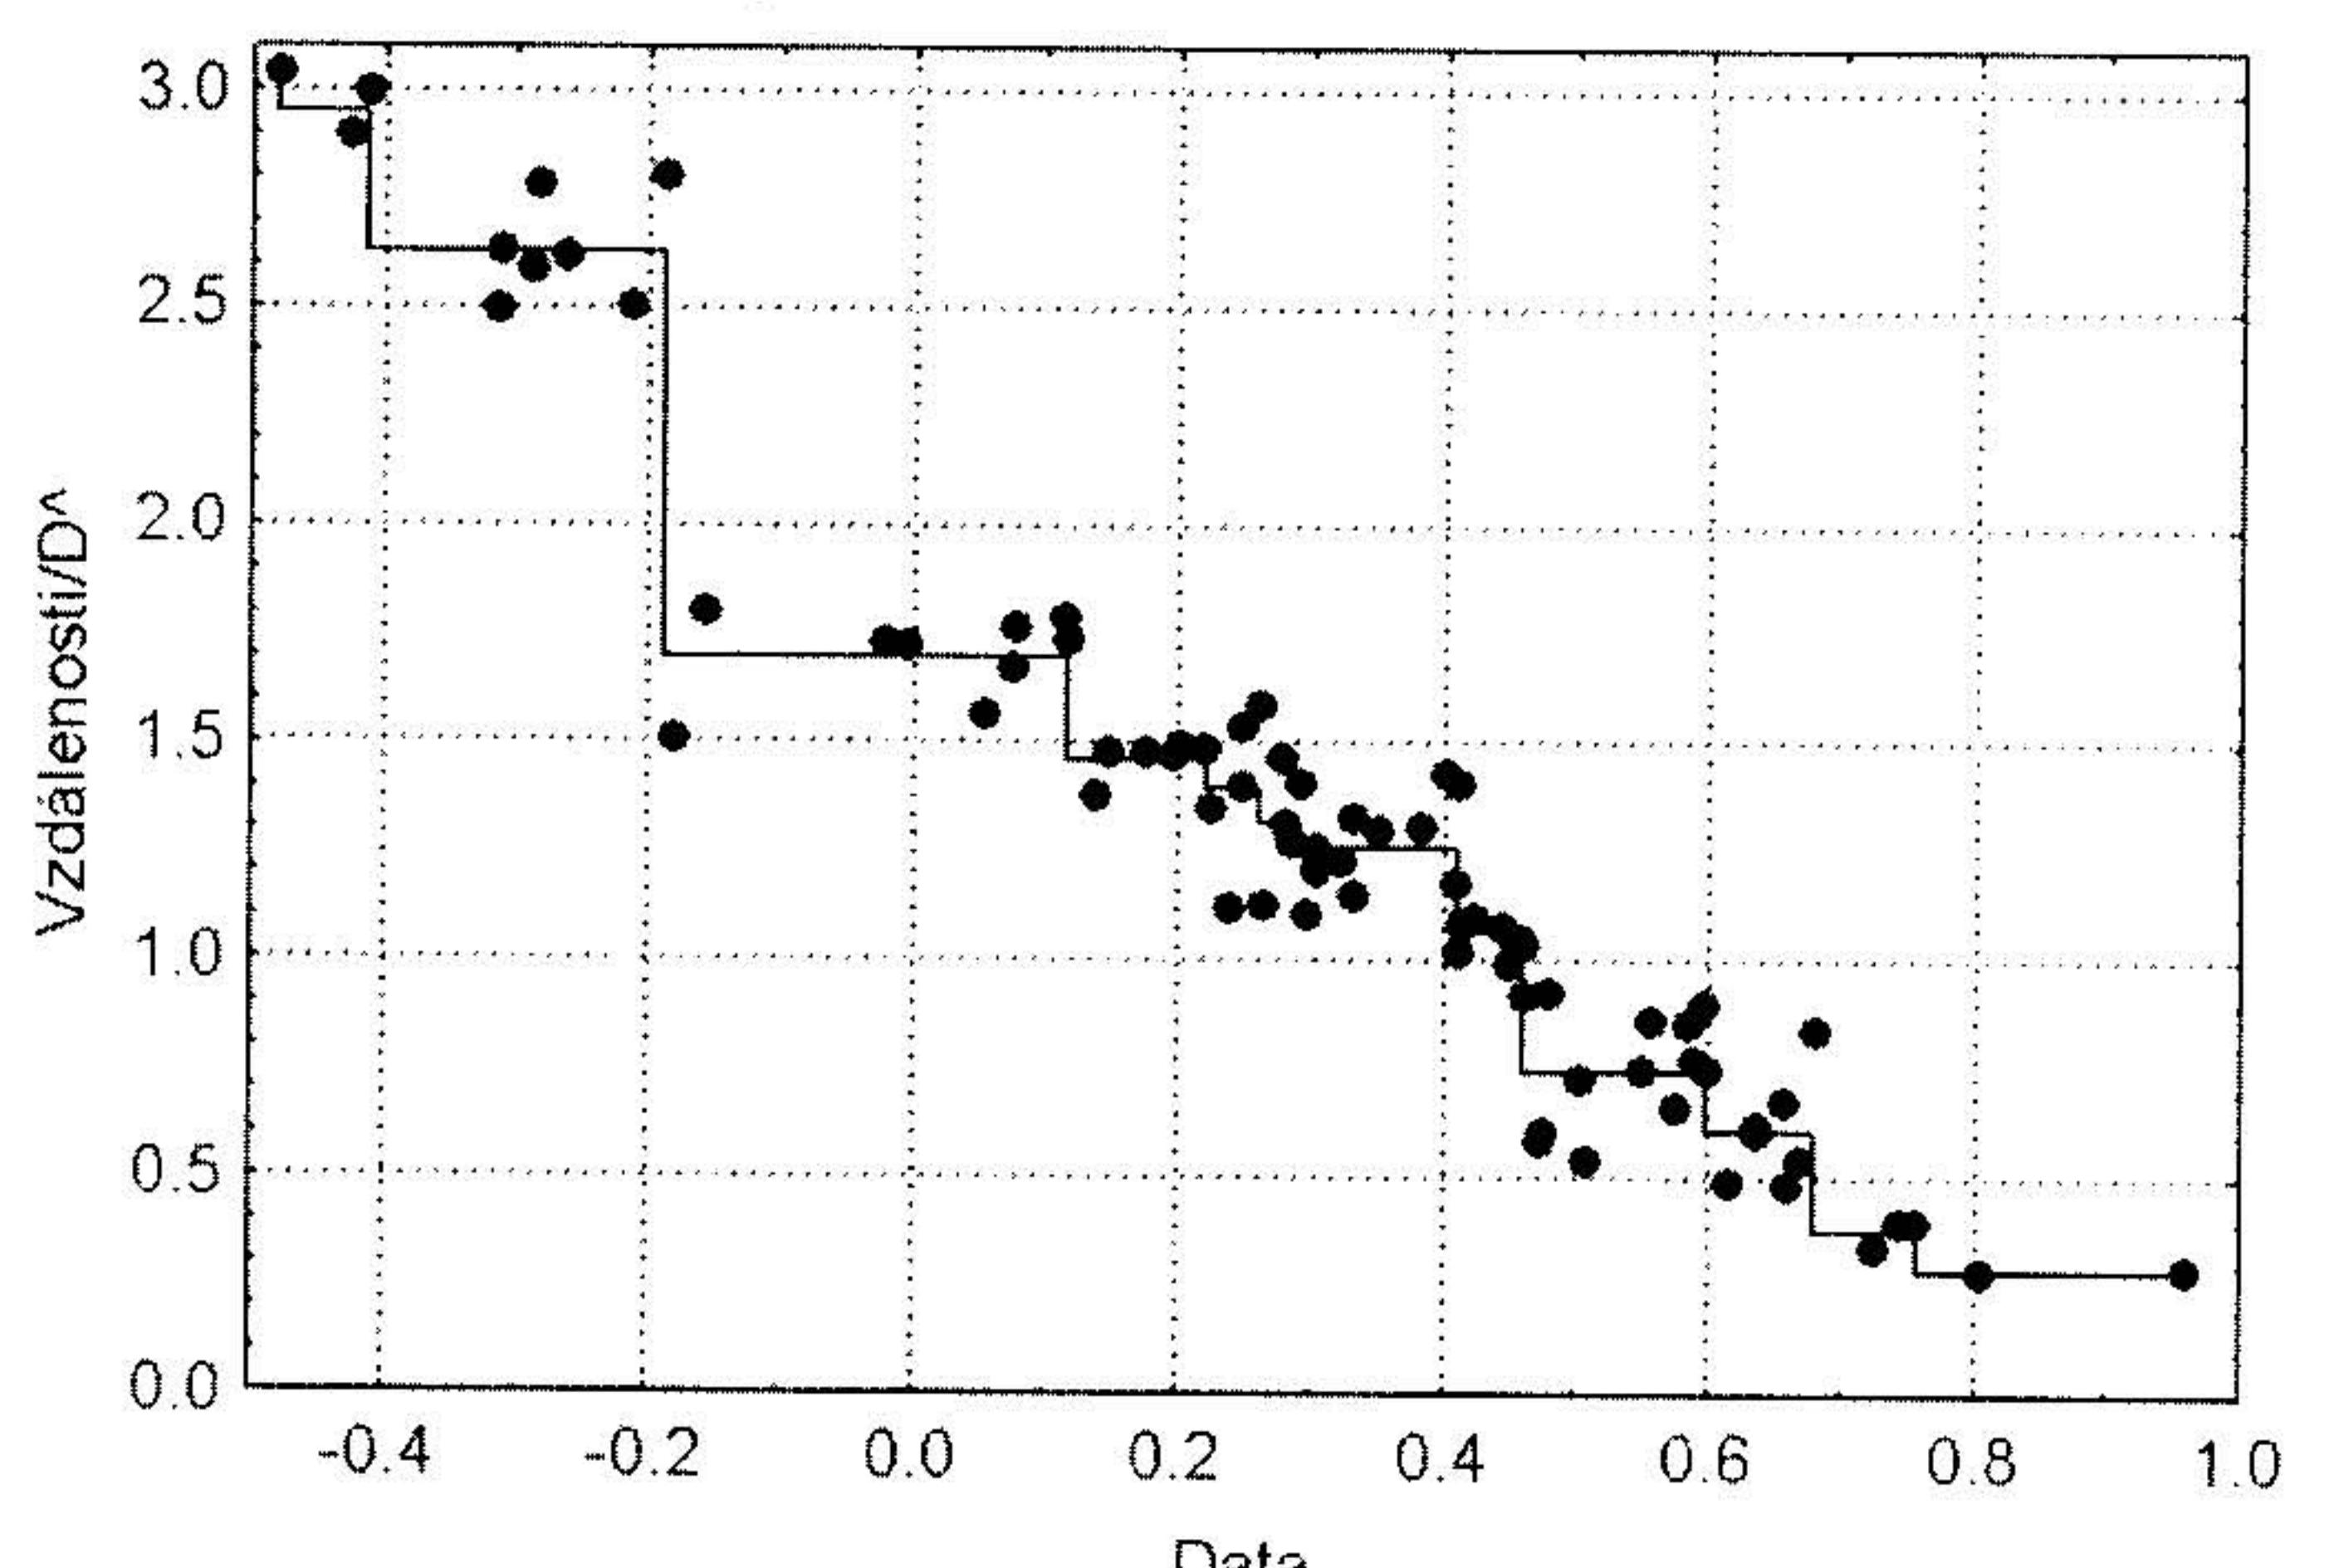
snadnější grafické zobrazení na co nejmenším počtu, nejčastěji dvou. Pro grafickou přehlednost budeme proto upřednostňovat především dvojrozměrný graf. Když by rozbor ukazoval na více než tři souřadnice, nebyla by mapa MDS pak už vhodnou technikou pro tuto úlohu. Jednotlivé i kumulativní procento proměnlivosti v datech pomocí vlastních čísel se jeví jako užitečné kritérium k určení vhodného počtu použitelných souřadnic. Kritérium ukazuje, že největší hrana je zde u 3 souřadnic. První dvě souřadnice pokrývají 48 % proměnlivosti v datech zatímco první tři 63 %. Výhodnější se zde jeví užít první 3 souřadnice. Na hodnoty vlastních čísel lze uplatnit také grafické zobrazení formou Cattelova indexového grafu úpatí vlastních čísel formou čárového diagramu a určit tak spolehlivě počet využitelných souřadnic (tab. 2).

Tabulka 2. Cattelův indexový graf vlastních čísel v tabelární formě a ve formě čárového grafu

Index	Vlastní číslo	Jednotlivé %	Kumulativní %	Čárový graf
1	2.14	25.26	25.26	IIIIIIIIIIII
2	1.91	22.56	47.82	IIIIIIIIII
3 (Used)	1.33	15.66	63.48	IIIIII
4	0.84	9.91	73.39	III
5	0.59	6.93	80.33	III
6	0.55	6.47	86.79	III
7	0.38	4.43	91.22	II
8	0.33	3.94	95.17	II
9	0.25	2.95	98.12	I
10	0.09	1.01	99.13	I
11	0.06	0.66	99.78	
12	0.02	0.22	100.00	
13	0.00	0.00	100.00	



Shepardův diagram, ● Vzdálenosti a —  $D^*$  vs. data



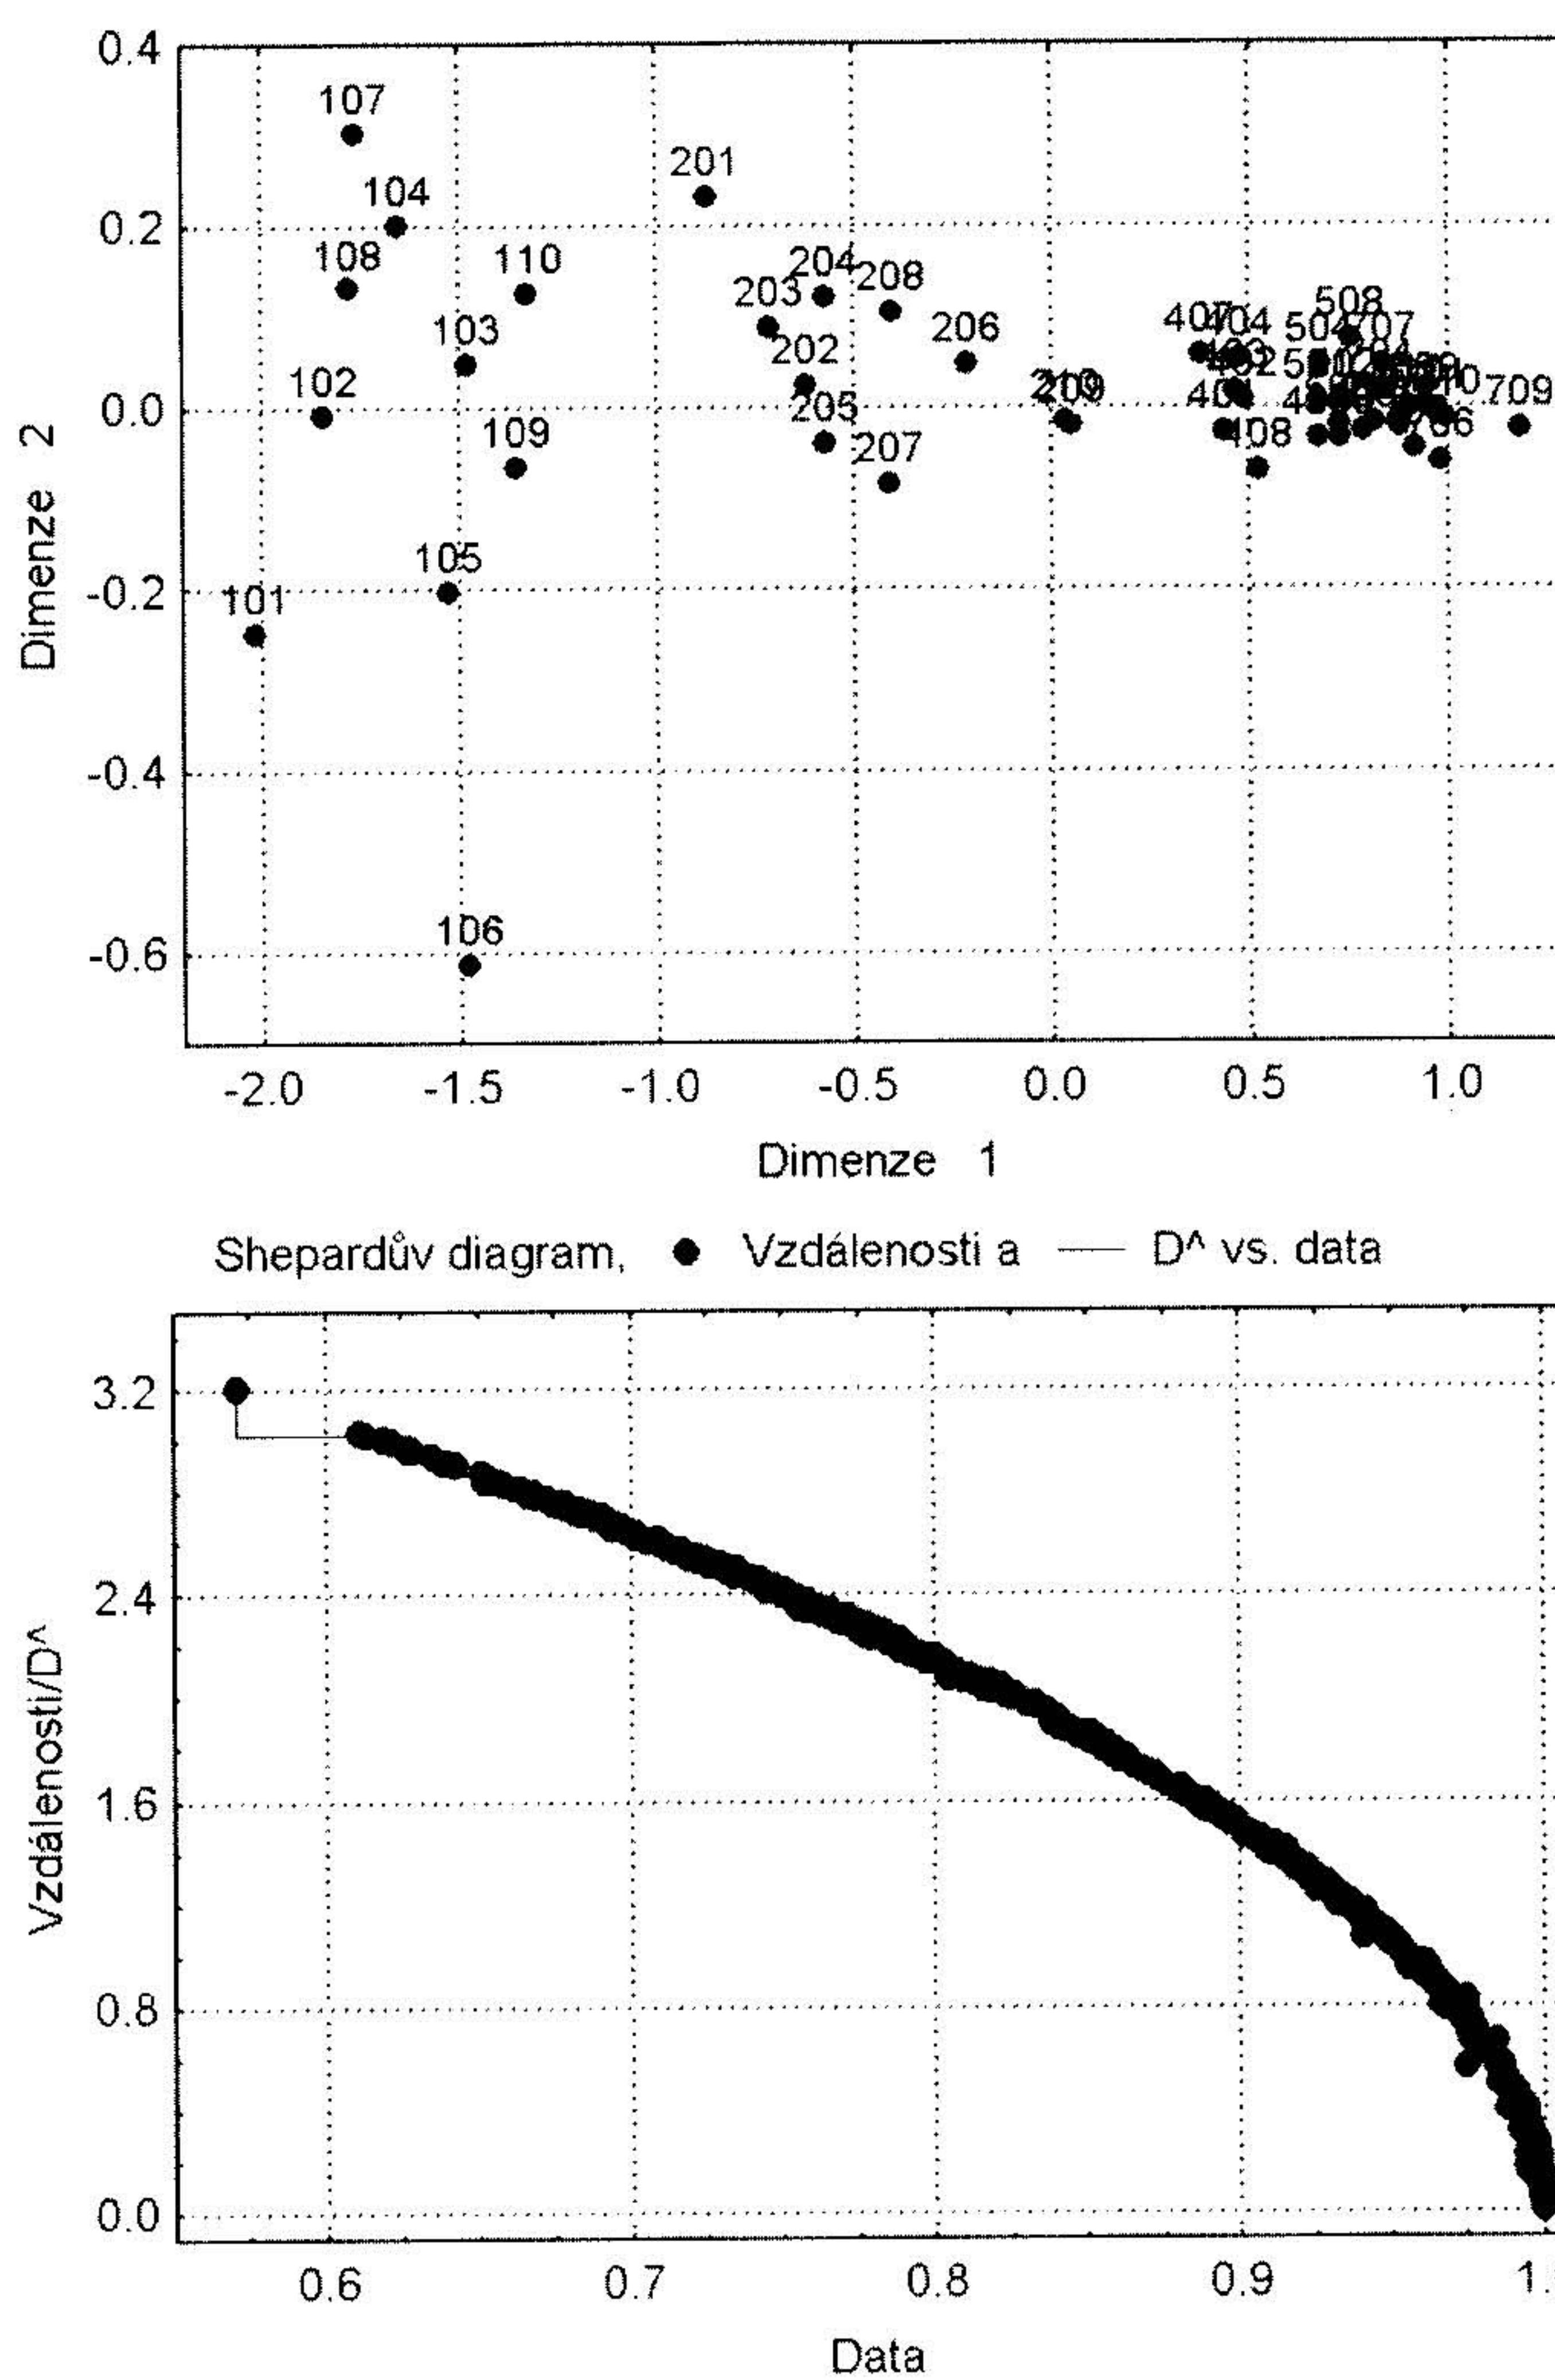
Obr. 5. (a) 2D-subjektivní mapa vícerozměrného škálování MDS znaků a (b) Shepardův diagram ukazují na shluky podobných znaků,  $\hat{D}$ : čistý stress = 1.98, stress = 0.11,  $D^*$ : čistý stress = 3.45, STATISTICA.

b) **Optimalizace výpočtu vzdáleností.** Iterační algoritmus v programu STATISTICA nebo NCSS2000 provádí minimalizaci účelové funkce a hledá optimální sestavu vypočtených vzdáleností ve dvou krocích; v prvém kroku aplikuje iterace minimalizační metody největšího spádu. Po každé iteraci provede 5 dalších zjemnění odhadů parametrů a vyčíslí kritérium stress. Při minimalizaci účelové funkce jsou vyčísleny dvojí hodnoty vektoru vypočtené vzdálenosti, ze kterých jsou pak vyčíslována rezidua,  $d_{vyp}$  (metricky) a  $d^{*}_{vyp}$  (nemetricky). Zatímco  $d_{vyp}$  představuje monotónní regresní transformační odhad minimalizace funkcí, je druhá vzdálenost  $d^{*}_{vyp}$  vypočtena permutační procedurou vzestupných pořadí, jež se snaží vyčíslit co nejtěsnější vypočtená pořadová čísla vůči skutečným zadaným.

Jako v každé analýze dat, i zde je třeba posoudit, jak dobré model MDS prokládá data vzdáleností zadané matice proximity. Budeme proto vyšetřovat, jak jsou vypočtené vzdálenosti mezi analytickými znaky blízké skutečným vzdálenostem, což vyžaduje použít kritérium těsnosti proložení stress. Toto kritérium je současně také funkci počtu použitých souřadnic v modelu CMDS. Vhodný počet použitelných souřadnic je demonstrován v tabulce 3.

Tabulka 3. Těsnost proložení pro rozličný počet souřadnic sledovaná pomocí kritéria stress

Užitých souřadnic	Čtverec reziduí	Stress	Pseudo R <sup>2</sup>
1	49.025606	0.667532	0.00
2	19.872060	0.424993	0.00
3	10.570773	0.309966	0.00
4	5.024119	0.213693	14.68
Počet vzdáleností		78	
Průměr vzdáleností		1.155441	
Suma čtverců vzdáleností		110.021913	



Obr. 6. (a) 2D-subjektivní mapa vícerozměrného škálování MDS objektů-odběrných míst na Vltavě v rozličném měsíci a (b) Shepardův diagram ukazují na shluky podobných objektů,  $\hat{D}$ : čistý stress = 0.28, stress = 0.011,  $D^*$ : čistý stress = 0.38, STATISTICA.

Ve sloupci Čtverec reziduů značí reziduum rozdíl mezi vypočtenou a skutečnou vzdáleností analytických ukazatelů. Stress se rovná odmocnině ze čtverců reziduů dělených odmocninou sumy čtverců vzdáleností. Hodnoty menší než 0.05 jsou přijatelné a hodnota menší než 0.01 se považuje za dobrou. Pseudo R<sup>2</sup> ukazuje na procento sumy čtverců vzdáleností, která je vypočtena pro tento počet souřadnic. Hodnota větší než 80 % je považována za velmi nadějnou. Suma čtverců vzdáleností je hodnota užitá ve jmenovateli vzorce pro stress. Suma čtverců vzdáleností okolo jejich průměru je hodnota užita ve jmenovateli vzorce Pseudo R<sup>2</sup>.

c) **Mapa objektů.** Subjektivní mapa MDS (obr. 5a a 6a) představuje vlastně cíl celé analýzy MDS. Mapa je dostupná především v grafické podobě. Umožňuje vysvětlit vstupní matici dat, tj. matici proximit obvykle ve dvojrozměrném rozptylovém diagramu. Protože byla předem škálována, je suma čtverců každého sloupce čili každé souřadnice rovna vlastnímu číslu této souřadnice (obr. 5a a 6a).

d) **Shepardův rozptylový diagram** (obr. 5b, 6b, 8a) zobrazuje vypočtené vzdálenosti (osa y) v závislosti na skutečných podobnostech (opak vzdáleností), viz osa x, a proto je křivka sestupná. Schodovitá křivka představuje spojitou monotónní transformaci  $d_{ij,vyp} = f(d_{ij})$  hodnot skutečných vzdáleností  $d_{ij}$ . Všechny body ležící těsně u křivky značí dobrý model MDS, zatímco body od křivky vzdálené pak nedostatečné proložení. Když je těsnost proložení při správně zvoleném počtu souřadnic velmi dobrá, jsou vypočtené vzdálenosti  $d_{vyp}$  (metricky) a  $d_{vyp}^*$  (nemetricky) v dobré shodě. Body, které se nebudou shodovat, představují odlehlé

hodnoty nebo nedostatečně těsné proložení. Ve dvojrozměrném škálovacím diagramu CMDS je třeba chápout, že zde není žádána pevná orientace souřadných os. Osy můžeme libovolně otáčet okolo počátku. Smyslem otočení je dosáhnout dostatečně názorné relativní polohy bodů a dobře separované shluky bodů.

Obr. 7 přináší porovnání 3D-subjektivní mapy objektů (obr. 7a) a 3D-subjektivní mapy znaků, analyticky-chemických ukazatelů (obr. 7b). Obě mapy názorně ukazují shluky objektů i shluky analytických ukazatelů, eventuálně i jejich interakci.

e) **Těsnost proložení statistickou reziduů.** Statistická analýza reziduů se týká rozdílů mezi skutečnými a vypočtenými vzdálenostmi dvojic porovnávaných analytických znaků. Jsou indikovány vzdálenosti v těch dvojicích znaků, které nejsou modelem dobře proloženy (obr. 8b, 8c).

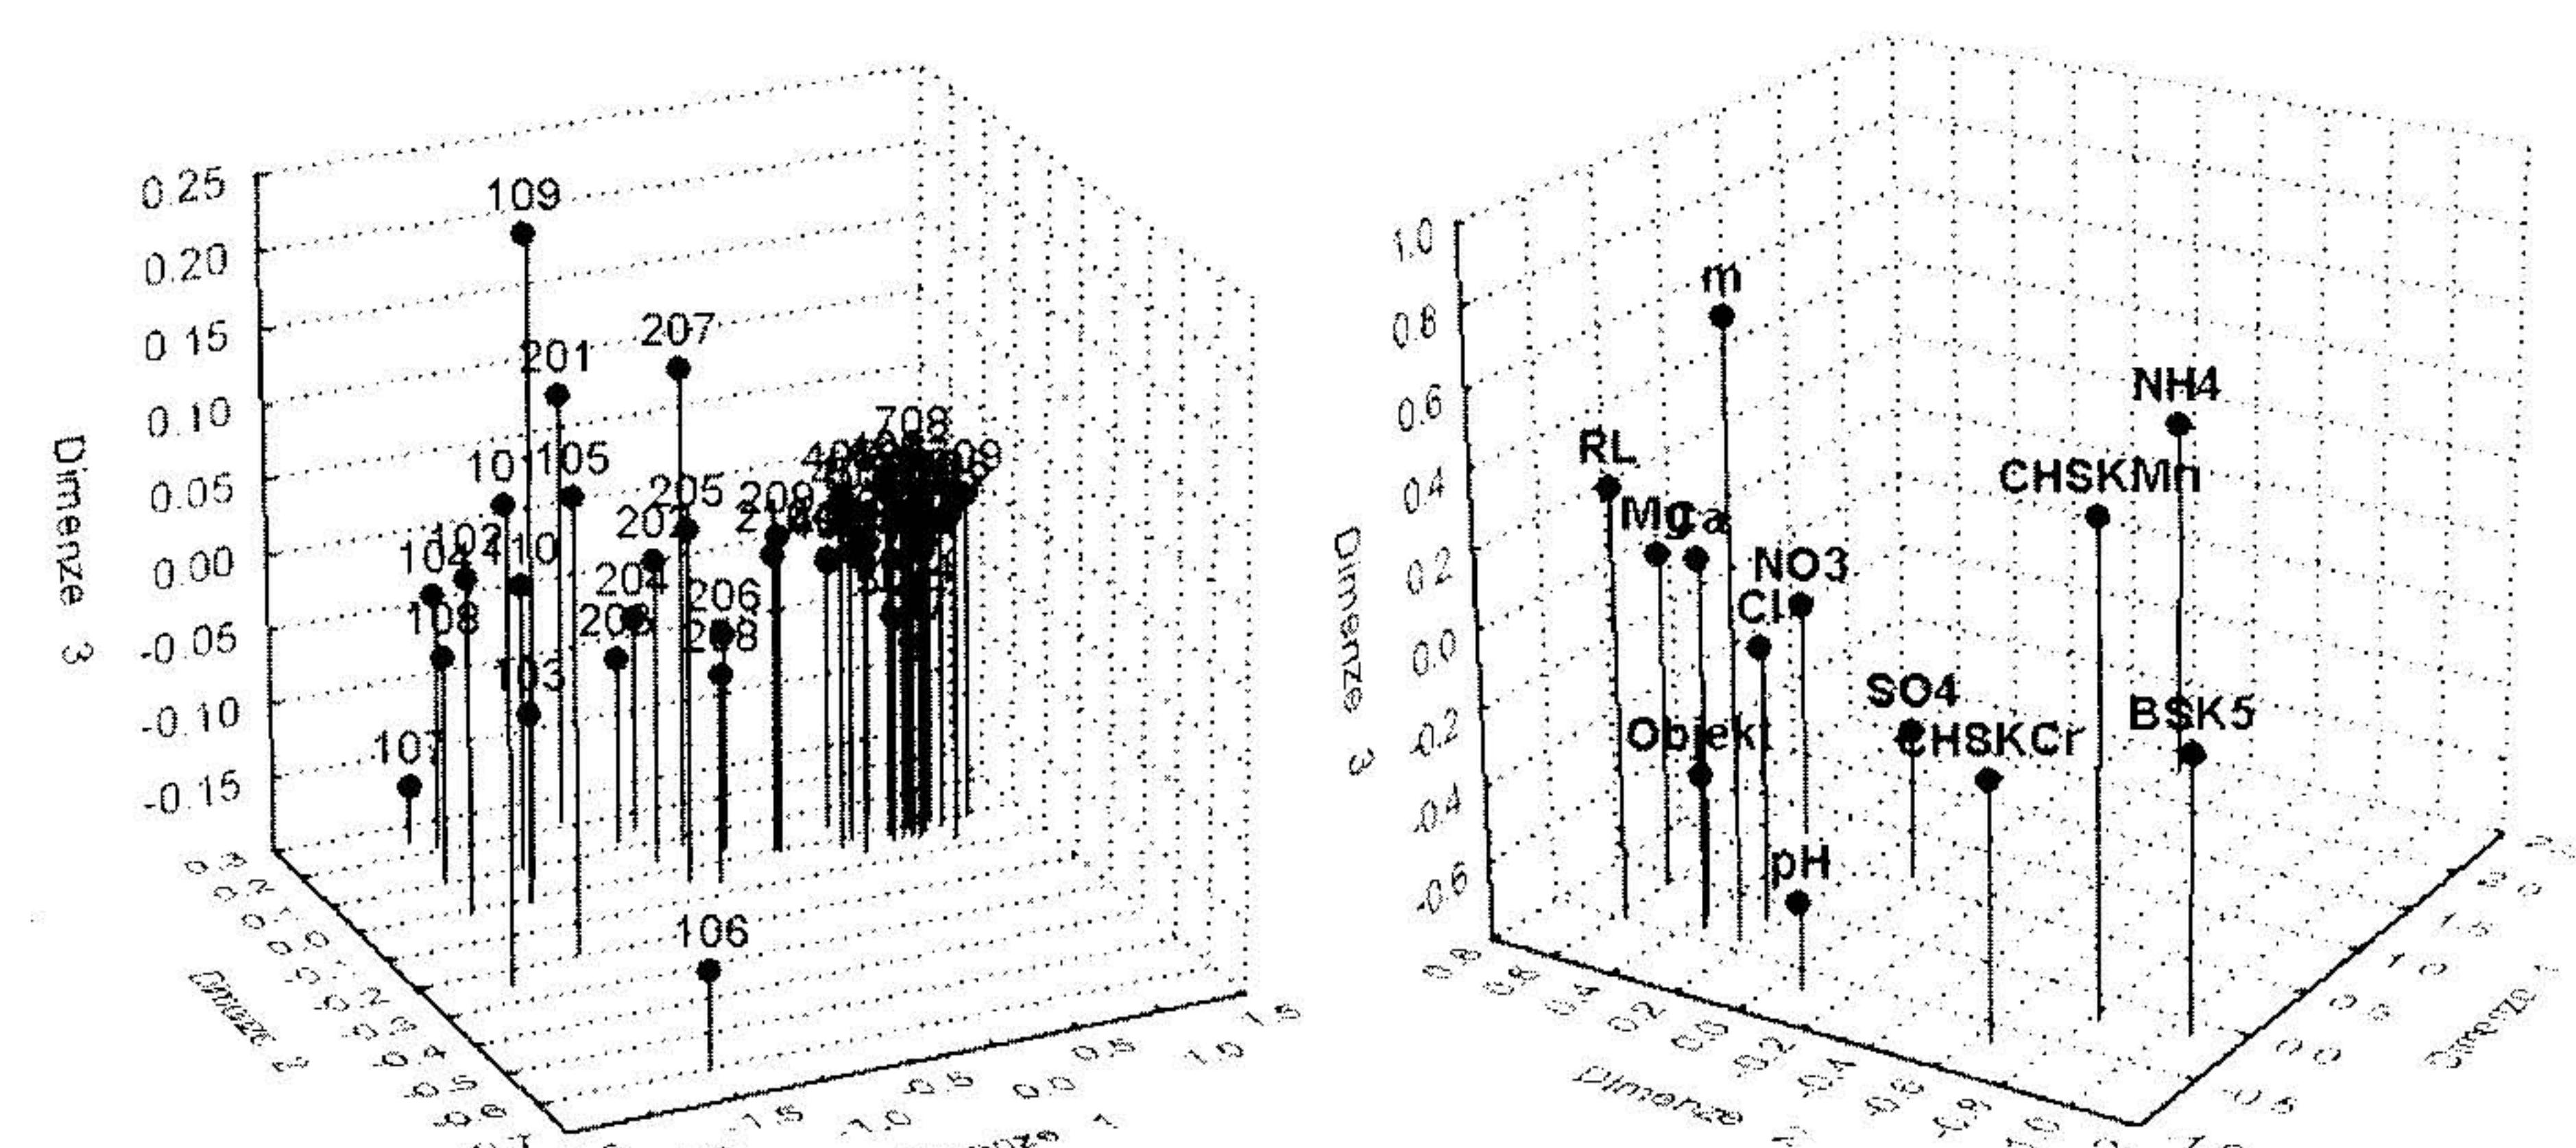
Tři průměty prostorového 3D-grafu z obr. 7b do tří rovin ukazuje obr. 9. Zřetelně jsou vidět shluky analytických ukazatelů v první a druhé souřadnici DIM1-DIM2, v první a třetí souřadnici DIM1-DIM3 a ve druhé a třetí souřadnici DIM2-DIM3. Zřetelný shluk je tvořen třemi znaky **BSK5**, **CHSKCr**, **CHSKMn** a další shluk je tvořen většinou anorganických iontů **Cl**, **RL**, **Ca**, **Mg**, **pH**.

Obr. 10 ukazuje 2D-subjektivní mapu znaků (a), 2D-subjektivní mapu objektů čili odběrných míst vody ve Vltavě (b) a konečně graf obojího dohromady na jedné společné mapě (c). Tento třetí graf má tu výhodu, že se v něm dá nalézt interakce objektu a znaku čili odběrné místo je charakterizováno jistým dominantním znakem.

**Poděkování:** Autoři vyslovují svůj dík za finanční podporu vědeckého záměru č. MSM0021627502.

## Literatura

- [1] K. Marhold, J. Suda: *Statistické zpracování mnohorozměrných dat v taxometrii*. Nakladatelství Karolinum, Praha 2002.
- [2] M. Siotani, T. Hayakawa, Y. Fujikoshi: *Modern Multivariate Statistical Analysis*. A Graduate Course and Handbook, American Science Press, Columbia 1985.
- [3] M. G. Kendall, A. Stuart: *The Advanced Theory of Statistics*. Vol. III. New York 1966.
- [4] A. Raveh: *Amer. Statist.* 39, 39 (1985).
- [5] W. James, C. Stein: *Estimation with Quadratic Loss*, Proceed. 4th Berkeley Symp. on Math. Statist., s. 361, 1961.
- [6] R. A. Maronna, R. H. Zamar: *Technometrics* 44, 307 (2002).
- [7] N. A. Campbell: *Appl. Statist.*, 29, 231 (1980).
- [8] W. L. Poston a kol.: *J. Comput and Graphical Statist.* 6, 300 (1997).
- [9] P. J. Rousseeuw, K. Driessen: *Technometrics* 41, 212 (1999).
- [10] W. K. Fung: *The Statistician* 48, 73 (1999).
- [11] J. Muruzahal, A. Muñoz: *J. Comput. and Graph. Statist.* 6, 355 (1977).
- [12] A. S. Hadi: *J. R. Stat. Soc.*, B56, 393 (1994).
- [13] D. Peña, F. Prieto: *Technometrics* 43, 286 (2001).
- [14] H. Kres: *Statistical Tables for Multivariate Analysis*. Springer, New York 1983.
- [15] E. Stryjewska, E. S. Rubel, A. Henrion, G. Henrion: *Z. Anal. Chem.*, 327, 679 (1987).
- [16] G. S. Mudholkar, M. S. Trivedi, T. C. Lin: *Technometrics*. 24, 139 (1982).
- [17] N. Timm: *Applied Multivariate Statistics*. Springer 2002.
- [18] S. Wold: *Pattern Recognition* 8, 127–139 (1976).
- [19] V. Barnett (ed.): *Interpreting Multivariate Data*. Wiley, Chichester 1981.
- [20] J. M. Chambers, W. S. Cleveland, B. Kleiner, P. A. Tukey: *Graphical Methods for Data Analysis*. Duxbury Press, Belmont 1983.



Obr. 7. 3D-subjektivní mapa vícerozměrného škálování (a) objektů-odběrných míst vody na Vltavě a (b) sledovaných znaků-analytických ukazatelů čistoty vody,  $\hat{D}$ : čistý stress = 0.005, stress = 0.001,  $D^*$ : čistý stress = 0.011, STATISTICA.

*Data Analysis*. Duxbury Press, Belmont, California 1983.

- [21] M. S. Srivastava: *Methods of Multivariate Statistics*, Wiley, New York 2002.
- [22] R. Bolton, W. J. Krzanowski: *Amer. Statist.* 53, 108 (1999).
- [23] G. P. Nason: *J. R. Stat. Soc. B* 63, 551 (2001).
- [24] M. Daszykowski, B. Walczak, D. L. Massart: *Chemometrics and Intell. Lab. Systems* 65, 97 (2003).
- [25] B. S. Everitt: *Graphical Techniques for Multivariate Data*. London 1978.
- [26] D. F. Andrews: *Biometrics* 28, 125 (1972).
- [27] I. T. Jolliffe: *Principal Component Analysis*. Springer Verlag, New York 1986.
- [28] S. R. Kulkarni, S. R. Paranjape: *Commun. Statist.* 13, 2511 (1984).
- [29] R. Guanadeskian R.: *Methods for Statistical Data Analysis of Multivariate Observations*. Wiley, New York 1977.
- [30] B. Kleiner, J. A. Hartigan: *J. Amer. Statist. Assoc.* 76, 260 (1981).
- [31] R. Guanadeskian, J. R. Kettenring: *Biometrics* 28, 80 (1972).
- [32] J. Hu, P. Skrabal, H. Zollinger: *Dyes and Pigments*, 8, 189 (1987).
- [33] G. A. F. Seber: *Multivariate Observations*. Wiley, New York 1984.
- [34] R. A. Johnson, D. W. Wichern: *Applied Multivariate Statistical Analysis*. Prentice Hall, 1982.
- [35] S. Ajvazin, Z. Bežajeva, O. Staroverov: *Metody vícerozměrné analýzy*. SNTL, Praha 1981.
- [36] M. Meloun, J. Militký: *Kompendium statistického zpracování dat*. Academia, Praha 2002.
- [37] M. Meloun, J. Militký: *Statistická analýza experimentálních dat*. Academia, Praha 2004.
- [38] STATISTICA, StatSoft CR, Podbabská 16, 160 00 Praha 6.
- [39] SCAN, Minitab Inc., Quality Plaza, 1829 Pine Hall Road, State College, USA.
- [40] THE UNSCRAMBLER, CAMO PROCESS AS, Nedre Vollgate 8, Oslo, Norsko.
- [41] STATGRAPHICS, Manugistics, Inc. 2115 East Jefferson Street, Rockville, Maryland, USA.

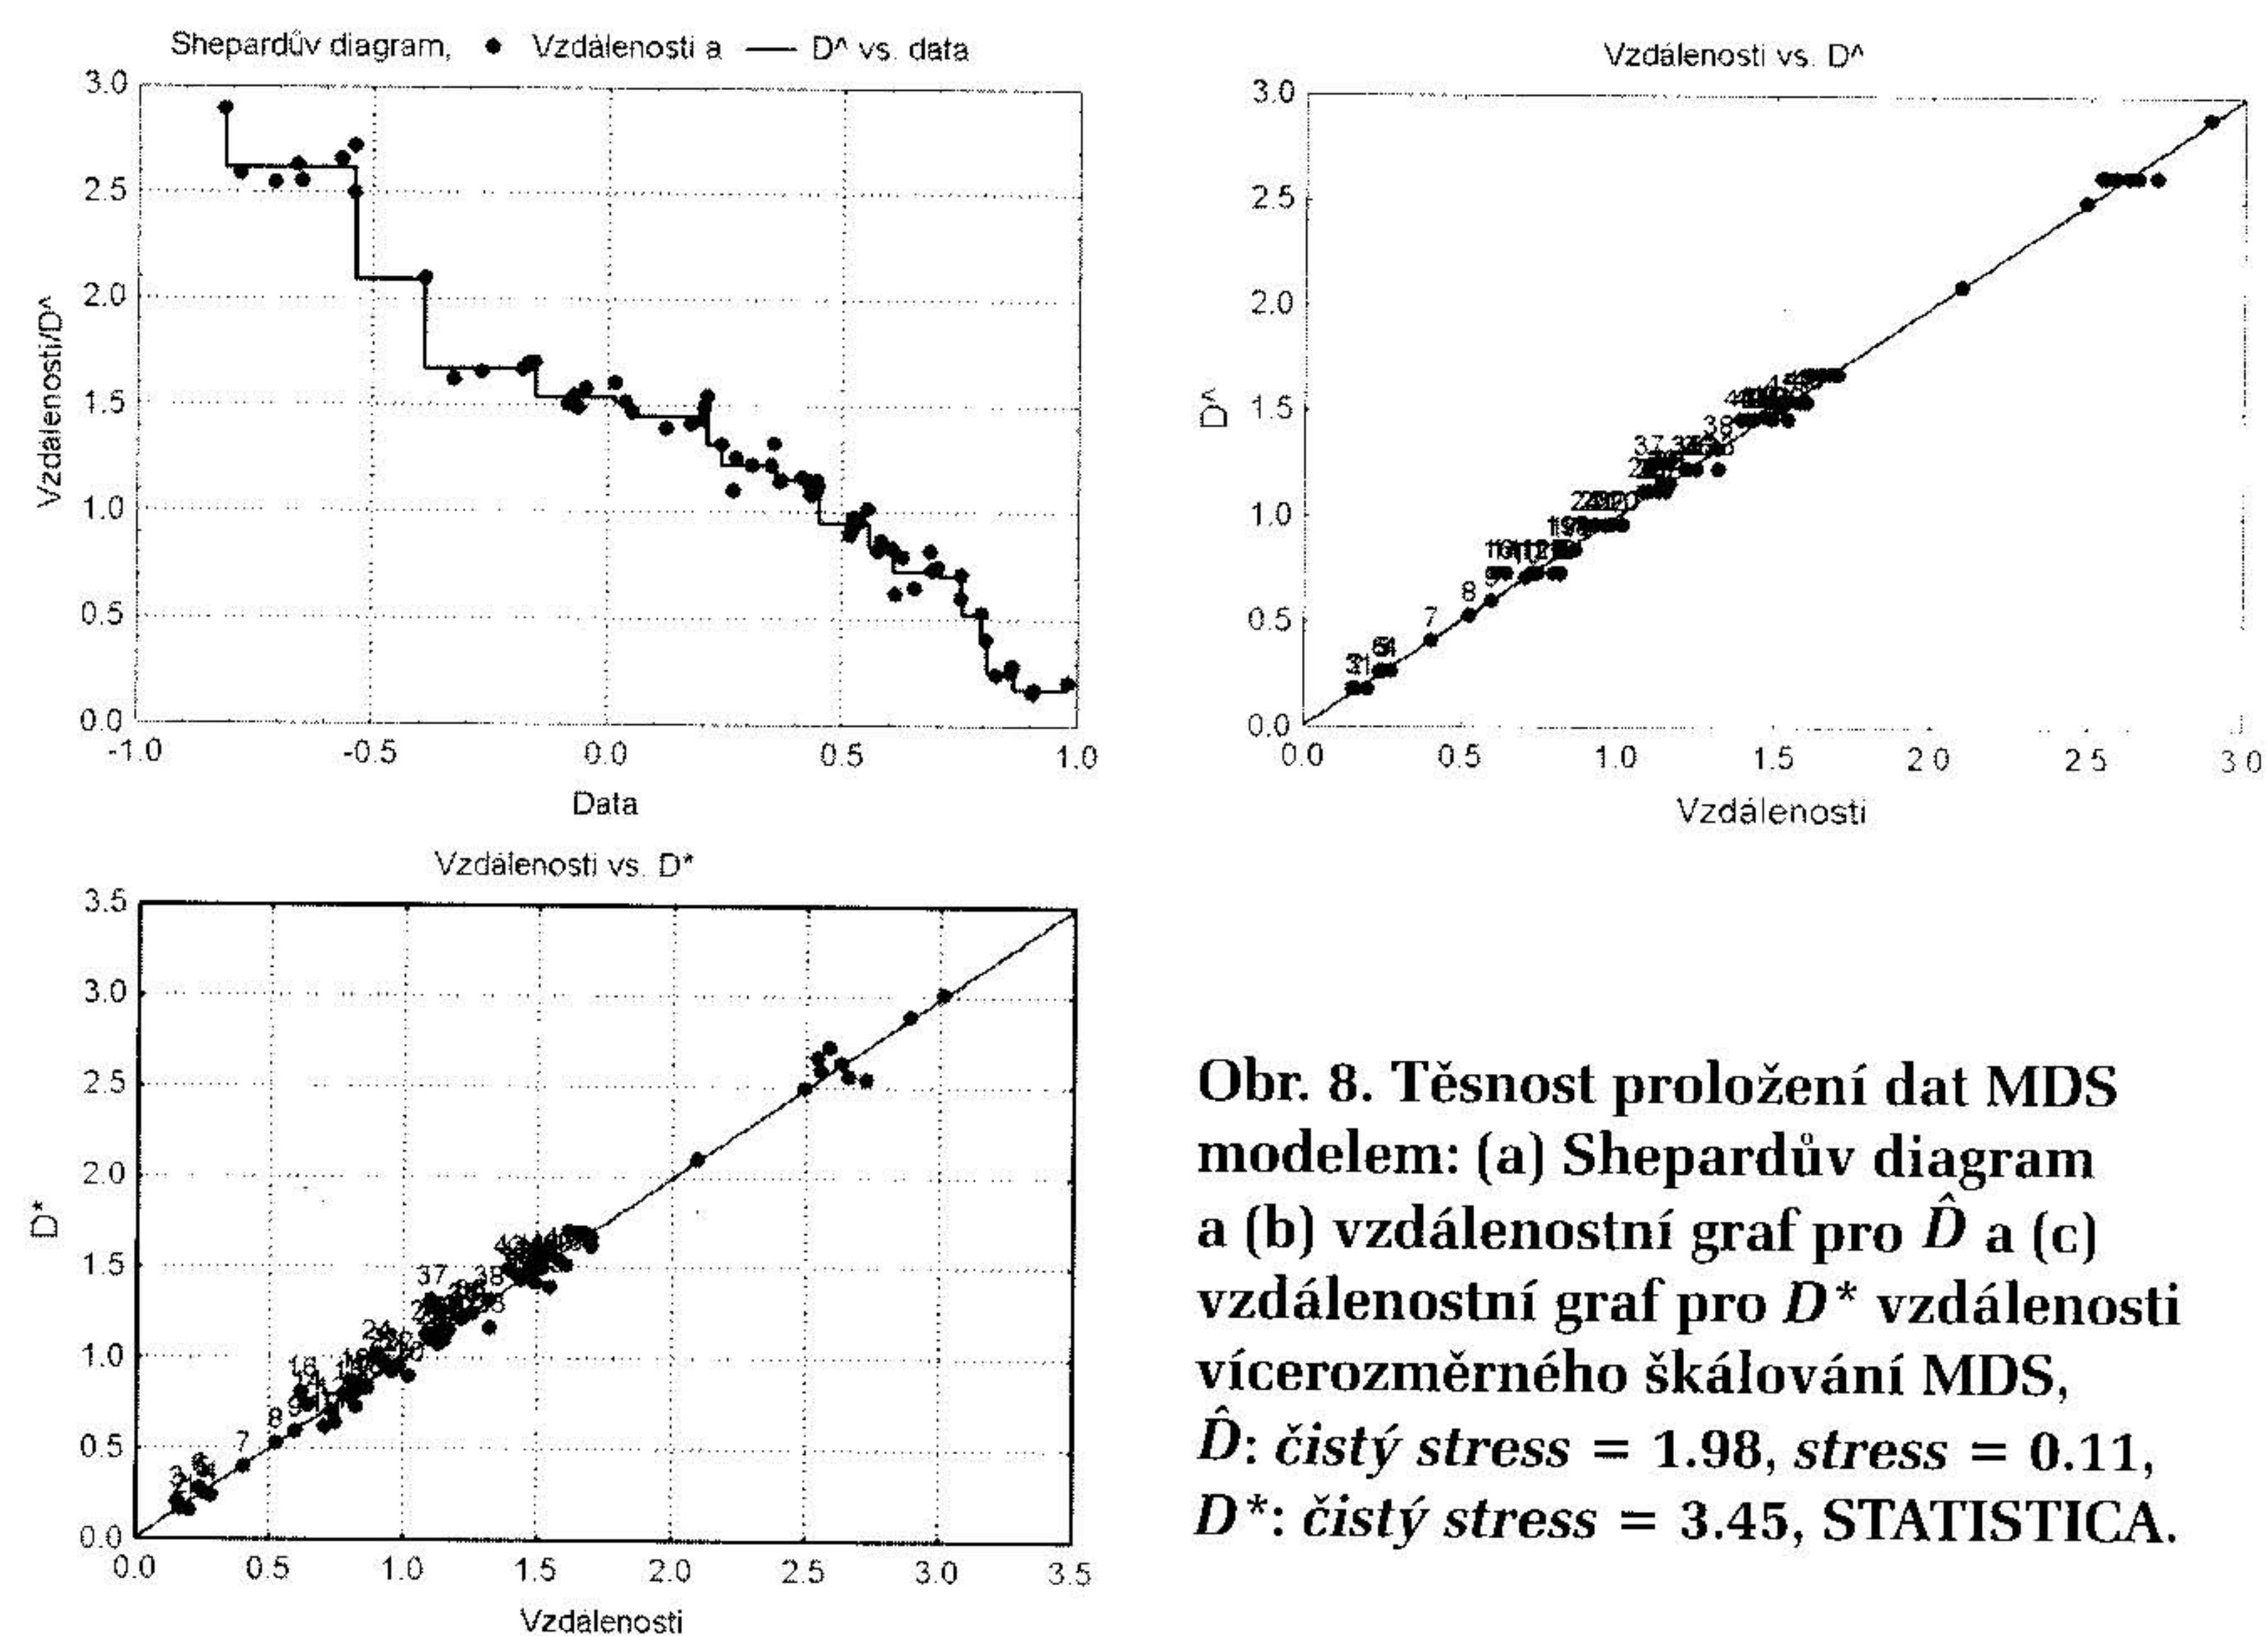
**Prof. RNDr. Milan Meloun, DrSc.**  
Katedra analytické Chemie,  
Chemickotechnologická fakulta  
Univerzita Pardubice  
Čs. Legií 565, 532 10 Pardubice  
tel.: 466 037 026, fax: 466 037 068,  
email: milan.meloun@upce.cz,  
<http://meloun.upce.cz>,  
ICQ: 224-001-003

*Computer-Assisted Statistical Data Analysis. 8. Analysis of the river water using multidimensional scaling MDS (Meloun, M.)*

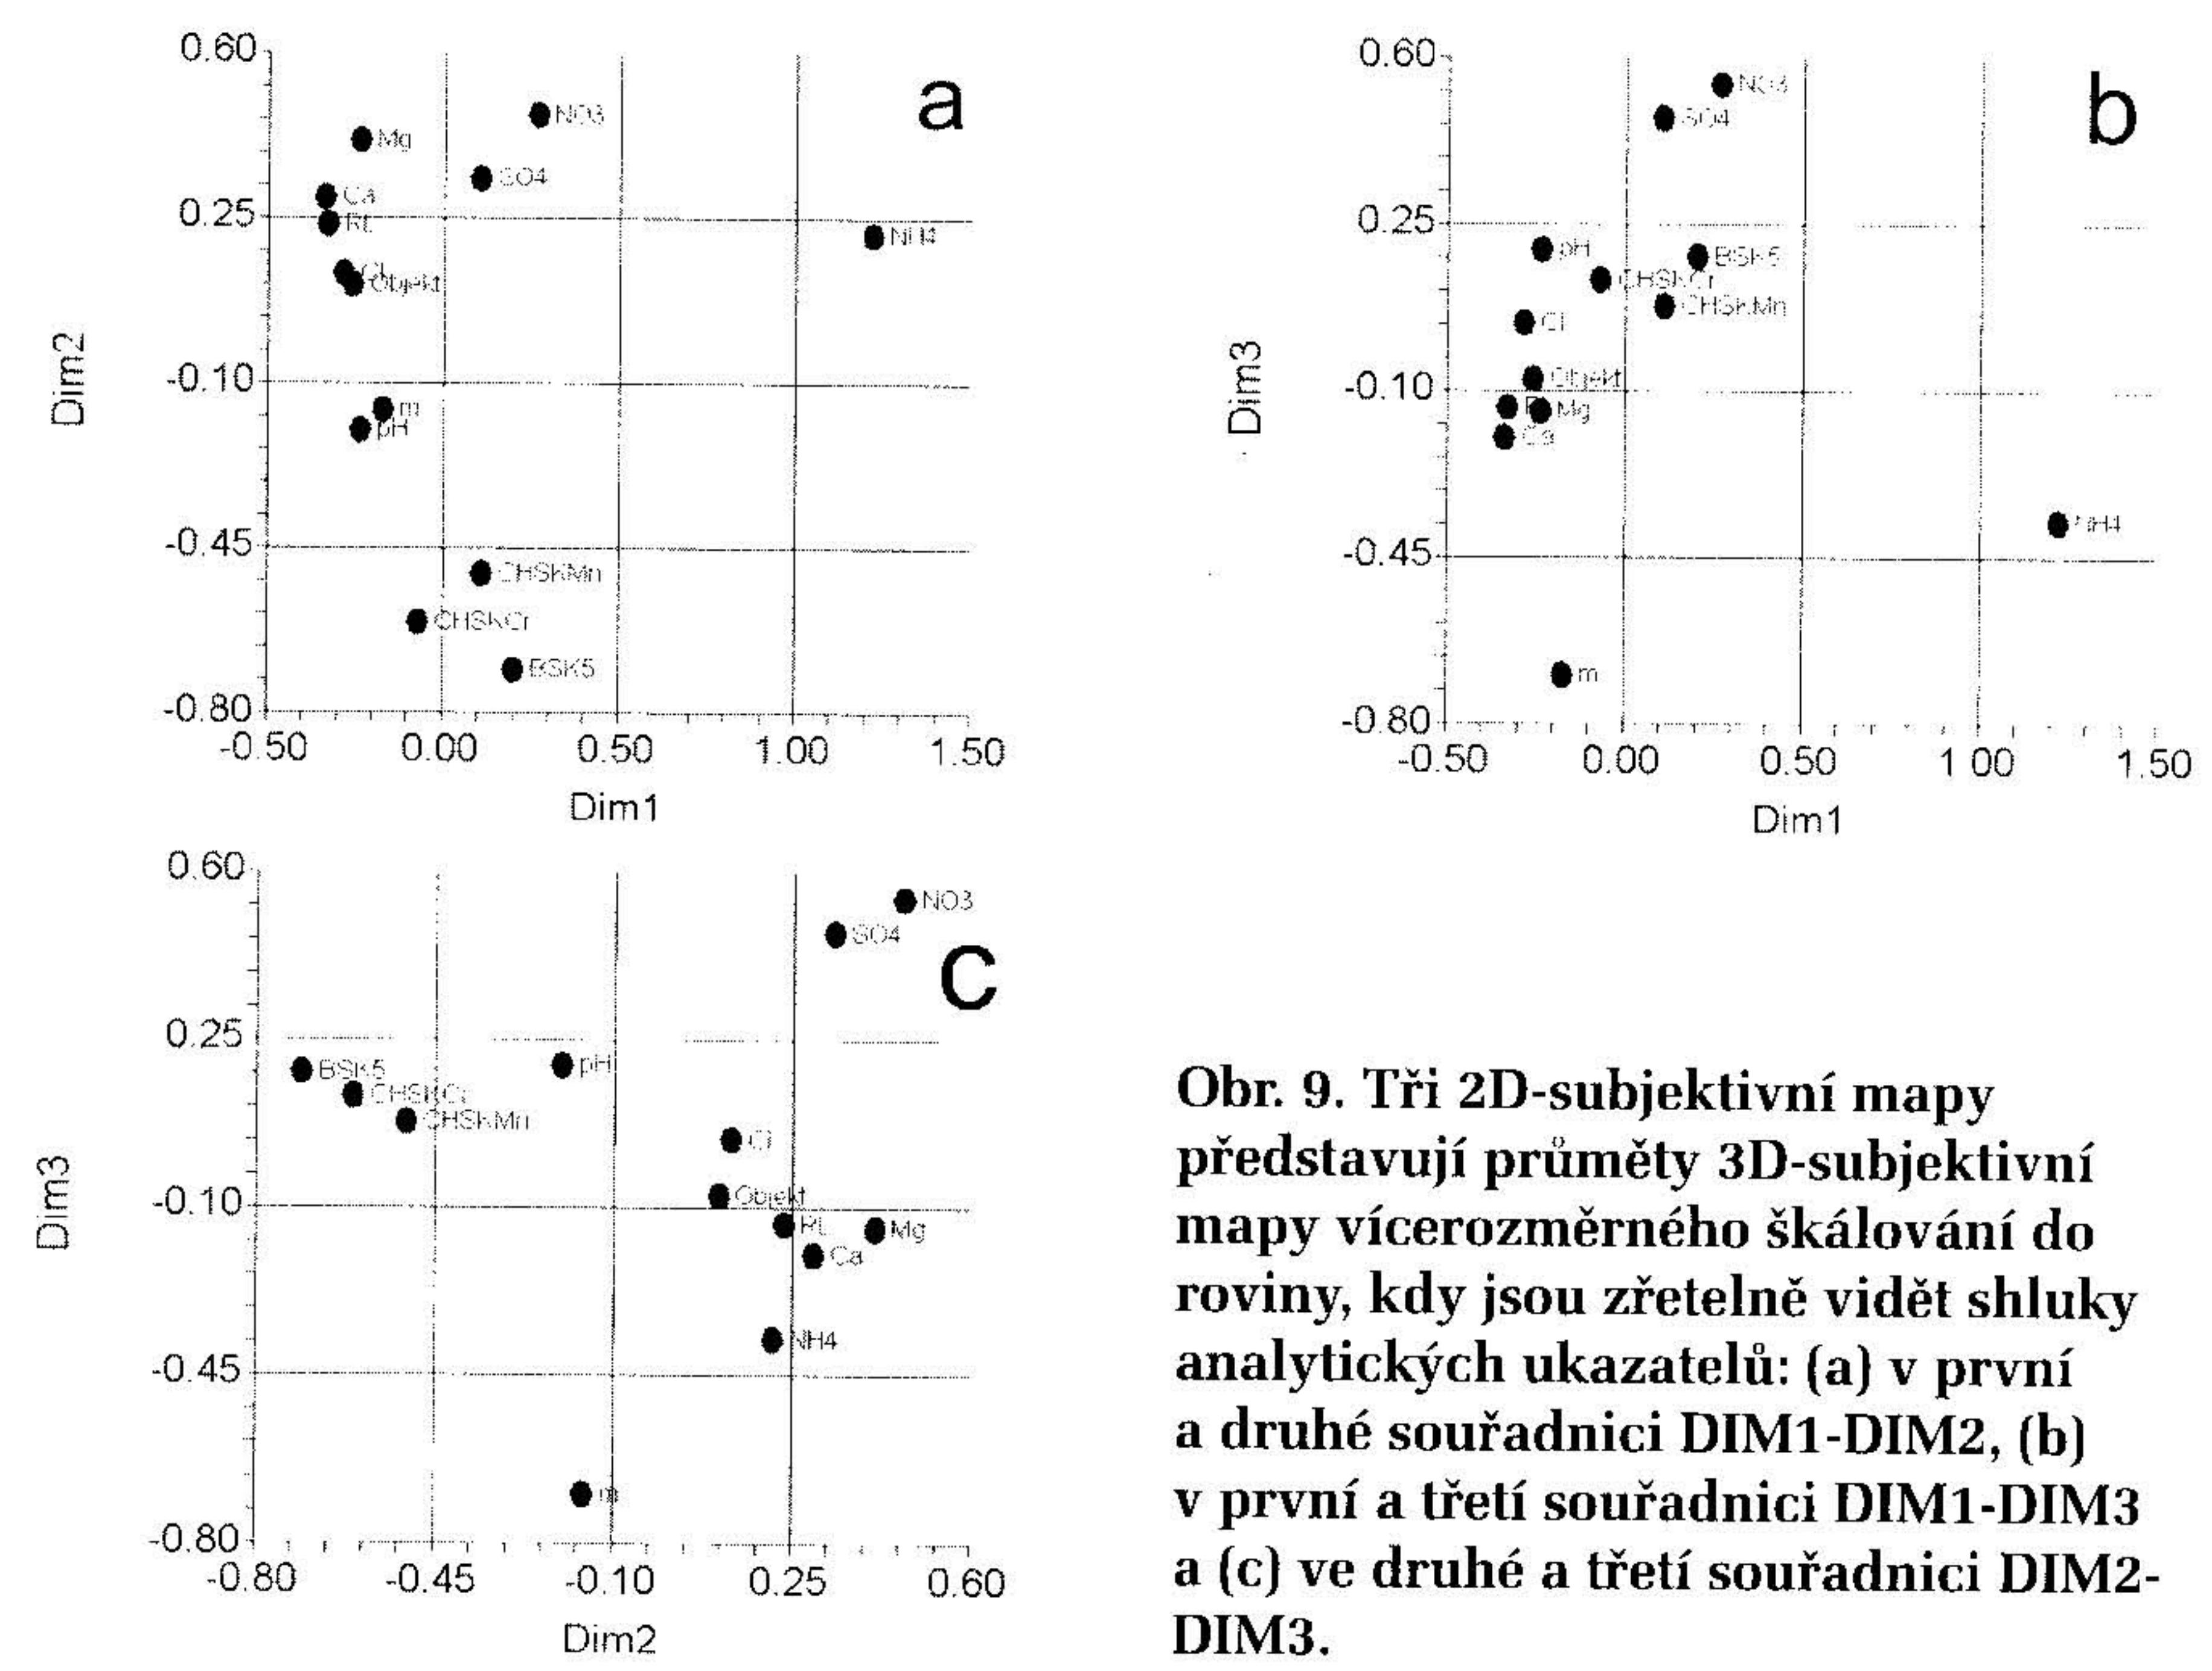
#### Key Words

*Multidimensional Scaling Analysis – Classical scaling – Nonmetric scaling – MDS – Dendrogram – River Water – Water analysis – Scatterplot – Scree Plot – Factor analysis – Principal Components analysis – Components Weight Plot*

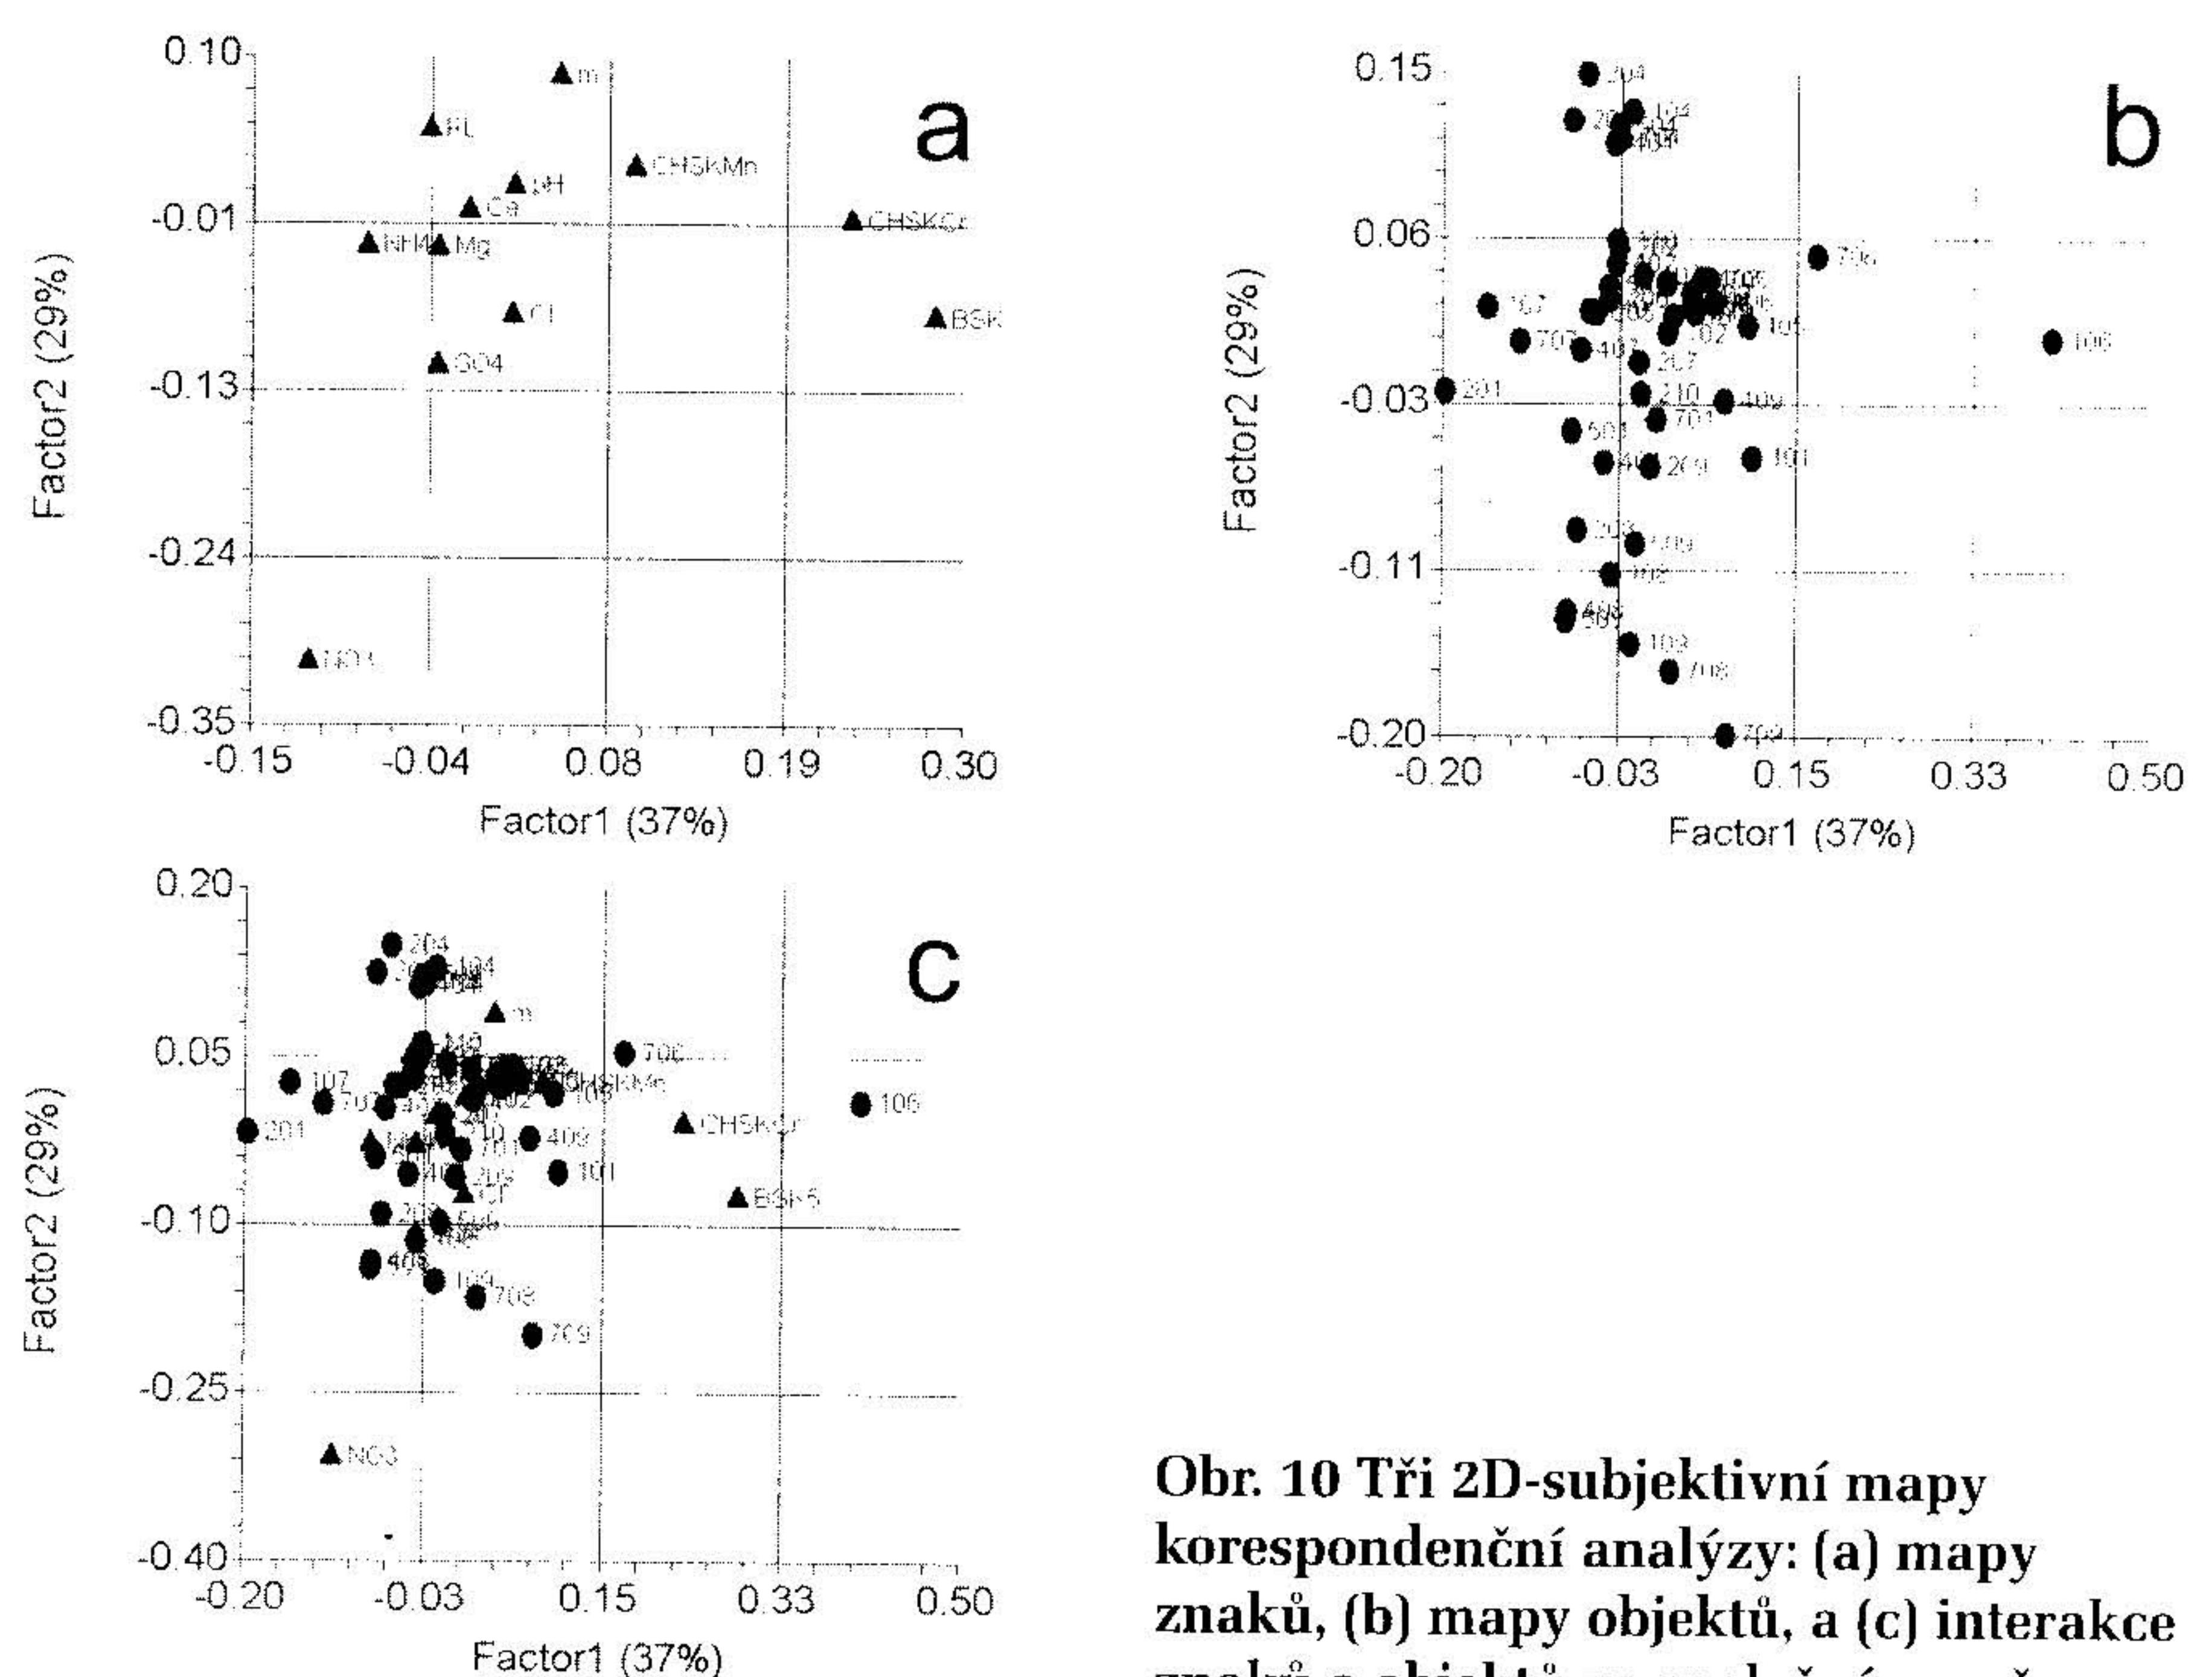
**Data matrix contains objects in  $n$  rows and  $m$  columns. Before data treatment the data are scaled. Similarity of objects and variables is considered on base on Mahalanobis distance or Euclidean distance in the  $m$ -dimensional space. Multidimensional**



**Obr. 8. Těsnost proložení dat MDS modelem:** (a) Shepardův diagram a (b) vzdálenostní graf pro  $\hat{D}$  a (c) vzdálenostní graf pro  $D^*$  vzdálenosti vícerozměrného škálování MDS,  $\hat{D}$ : čistý stress = 1.98, stress = 0.11,  $D^*$ : čistý stress = 3.45, STATISTICA.



**Obr. 9. Tři 2D-subjektivní mapy** představují průměty 3D-subjektivní mapy vícerozměrného škálování do roviny, kdy jsou zřetelně vidět shluky analytických ukazatelů: (a) v první a druhé souřadnici DIM1-DIM2, (b) v první a třetí souřadnici DIM1-DIM3 a (c) ve druhé a třetí souřadnici DIM2-DIM3.



**Obr. 10 Tři 2D-subjektivní mapy** korespondenční analýzy: (a) mapy znaků, (b) mapy objektů, a (c) interakce znaků a objektů ve společné mapě.

scaling MDS is a generic term for a class of techniques that attempt to construct a low-dimensional geometrical representation of a proximity matrix for a set of stimuli, with the aim of making any structure in the data as transparent as possible. The aim of all such techniques is to find a low-dimensional space in which points in the space represent the stimuli, one point representing one stimulus, such that the distances between the points in the space match as well as possible in some sense the original dissimilarities or similarities. In a very general sense this simply means that the larger the observed dissimilarity value between

two stimuli, the further apart should be the points representing them in the derived spatial solution. The principal components analysis reduces dimensionality and presents objects in two or three dimensions. The plot of components weight shows hidden structure among variables while the scatterplot shows the hidden structure of objects. The cluster analysis leads to clusters which may be plotted in dendrogram. There are two dendograms available, the dendrogram of variables and the dendrogram of objects. Both statistical techniques are demonstrated on the analysis and classification of various sources of a river water.

## **Deltares – Holandský institut pro problematiku říčních delt v národním i mezinárodním měřítku**

Od 1. ledna 2008 vzniká v Nizozemí nová instituce – „Deltares“ – nezávislý ústav pro aplikovaný výzkum a speciální poradenství.

Nový institut slučuje předchozí (nám velmi dobře známý) ústav Water Laboratories Delft Hydraulics, dále GeoDelft a také sekci Subsurface and Groundwater ústavu TNO, včetně začlenění části úřadu pro vody – Rijkswaterstaat.

Očekávanými výhodami této nové instituce jsou komplexní, inovativní řešení vodohospodářských problémů, které vznikají na celém světě následkem rozkolísání vodního režimu, nárůstu zranitelných oblastí na pobřeží a v neposlední řadě následkem ekonomických a hospodářských tlaků na využití území v deltách, údolních nivách a podél pobřeží moří s návaznými konflikty na ochranu životního prostředí.

Hlavním směrem činností je orientace na řešení problematiky území při ústích vodních toků, neboť přes 50% světové populace lidstva žije, pracuje anebo se rekreuje na pobřežích a v oblasti říčních delt. Tato území mají hlavní hospodářské přínosy – nejenom s ohledem na využití lodní přepravy, ale zároveň se zemědělstvím na úrodných půdách a souvisejícím rozšířením průmyslových zón. To vše přináší konfliktní situace vzhledem k dopadům na životní prostředí, což je třeba harmonizovaně řešit. Proto hlavní poslání nové instituce nejlépe vyjadřuje výrok: Integrovanými poznatkami s využitím modelových řešení, zapojením územních plánů a návrhem inovativních technologií „vyvinout a zlepšit podmínky pro obyvatelnost a využití delt vodních toků, pobřežních oblastí a hydrologických povodí... Tento přístup nazýváme „delta technologií“.

Kontaktní spojení a podrobnější informace na adresách: [info@deltares.nl](mailto:info@deltares.nl) a také [www.deltares.nl](http://www.deltares.nl).

RNDr. Pavel Punčochář, CSc.

(Převzato ze sdělení ředitelství WL / Delft Hydraulics.)

## **Česká vodohospodářská společnost ČSSI založena**

Oznamujeme, že byla založena nová odborná společnost **Česká společnost vodohospodářská ČSSI**, která má samostatnou právní subjektivitu na území České republiky. Společnost byla ustavena v září 2007 a je zapsaná v registru ČSÚ s IČO 75122031 a vedena v registru Ministerstva vnitra jako občanské sdružení podle zákona č.83/1990 Sb. pod č.j.VSP/1-1 798/90-R. ČSVH je dobrovolné neziskové sdružení stavovských a tvůrčích vodohospodářských pracovníků navazujících na tradice civilních vodohospodářských inženýrů, pracujících na principu dobrovolnosti.

Odborná společnost ČSVH se rozhodla působit ve 4 sekcích, a to: vodárenské, čistírenské, hydrotechnické a rybníkařské. Každá sekce má svého vedoucího, který řídí v součinnosti s výborem svoji činnost.

Základním posláním společnosti ČSVH v oblasti životního prostředí je vést své členy, vodohospodářské odborníky i širokou veřejnost k trvalému, setrnnému zacházení s vodou a tímto přispívat k šetření a tvorbě životního prostředí a tak vytvářet podmínky k jejímu trvale udržitelnému rozvoji. Toto vše zajišťovat v souladu s Evropskou vodní chartou vyhlášenou 6. května 1968 ve Strasbourgu. Podstatnou částí činnosti ČSVH je vzdělávání vodohospodářských pracovníků v rámci celoživotního vzdělávání (CŽV) a to jak svých, tak členů ČKAIT i ostatních organizací a technických pracovníků. Do programu vzdělávání zahrnuje ČSVH i Obecní úřady zejména s malým počtem obyvatel, kde je legislativní a odborná informovanost velice žádoucí. Součástí programu ČSVH je spolupráce s odbornými a vysokými školami jakož i s výzkumnými ústavy. Spolupráce je připravovaná při závěrečných absolventských prácech i při zadávání odborných témat.

Podrobně jsou cíle a poslání ČSVH uvedeny v Organizačním řádu společnosti, jakož i členství, organizační struktura a závěrečná ustanovení.

Členství je rádné, přidružené a čestné. Právnické osoby mohou být přidruženými členy ČSVH a mají omezené právomoce. Roční příspěvek rádného člena je 500,-Kč. Spolupráce se předpokládá prakticky v celé oblasti lidské činnosti, která souvisí s vodohospodářskou problematikou.

ČSVH uvítá ve svých řadách všechny odborníky příslušného vzdělání, kteří jsou ochotni dobrovolně pracovat v této společnosti v souladu s Organizačním řádem a dalšími platnými předpisy ČSSI.

Naše adresa: ČSVH.Novohradská 1, 37001 České Budějovice (kancelář ČKAIT), tel./fax.386352881, e-mail: [ckait@proactive.cz](mailto:ckait@proactive.cz).

Ing. Bohumil Kujal – předseda