Pokročilé metody analýzy dat v neurovědách

RNDr. Eva Koriťáková, Ph.D.

doc. RNDr. Ladislav Dušek, Dr.

Blok 5

Ordinační analýzy I

Osnova

1. Principy redukce dimenzionality dat
2. Selekce a extrakce proměnných
3. Analýza hlavních komponent (PCA)
4. Faktorová analýza (FA)

Principy redukce dimenzionality dat

Schéma analýzy a klasifikace dat

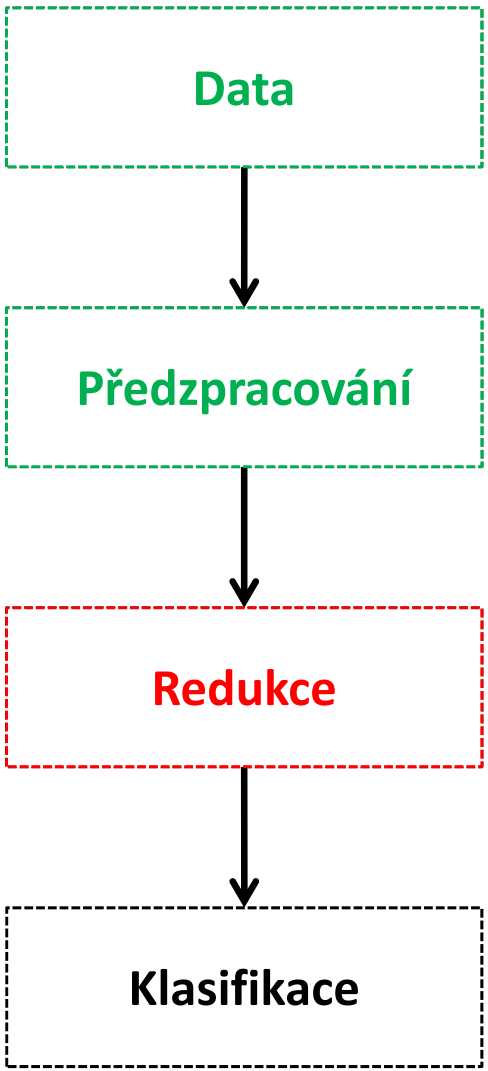

Ukázka - kognitivní data apod.

	A	B	C	D	E
1	id	vek	pohlavi	vyska	vaha
2	1	38	Z	164	45
3	2	36	M		90
4	3	26	Z	178	70

	A	B	C	D	E
1	id	vek	pohlavi	vyska	vaha
2	1	38	Z	164	45
3	2	36	M	167	90
4	3	26	Z	178	70

	A	B	C	D	E
1	id	vek	pohlavi	vyska	vaha
2	1	38	Z	164	45
3	2	36	M	167	90
4	3	26	Z	178	70


?

nebo


?

Ukázka - obrazová data

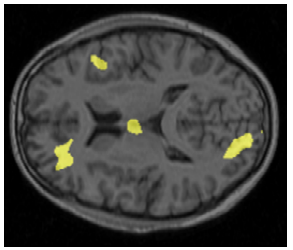

Proč používat redukci dat?

Obrazová data

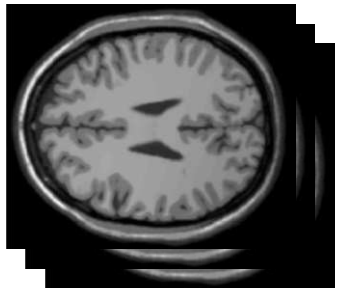

Klasifikace

X voxely

subjekty	x_1 x_2 …
I_1	270 x 1 000 000
I_2	
…	

subjekty	
I_1	pac.
I_2	kon.
…	

Proč používat redukci dat?

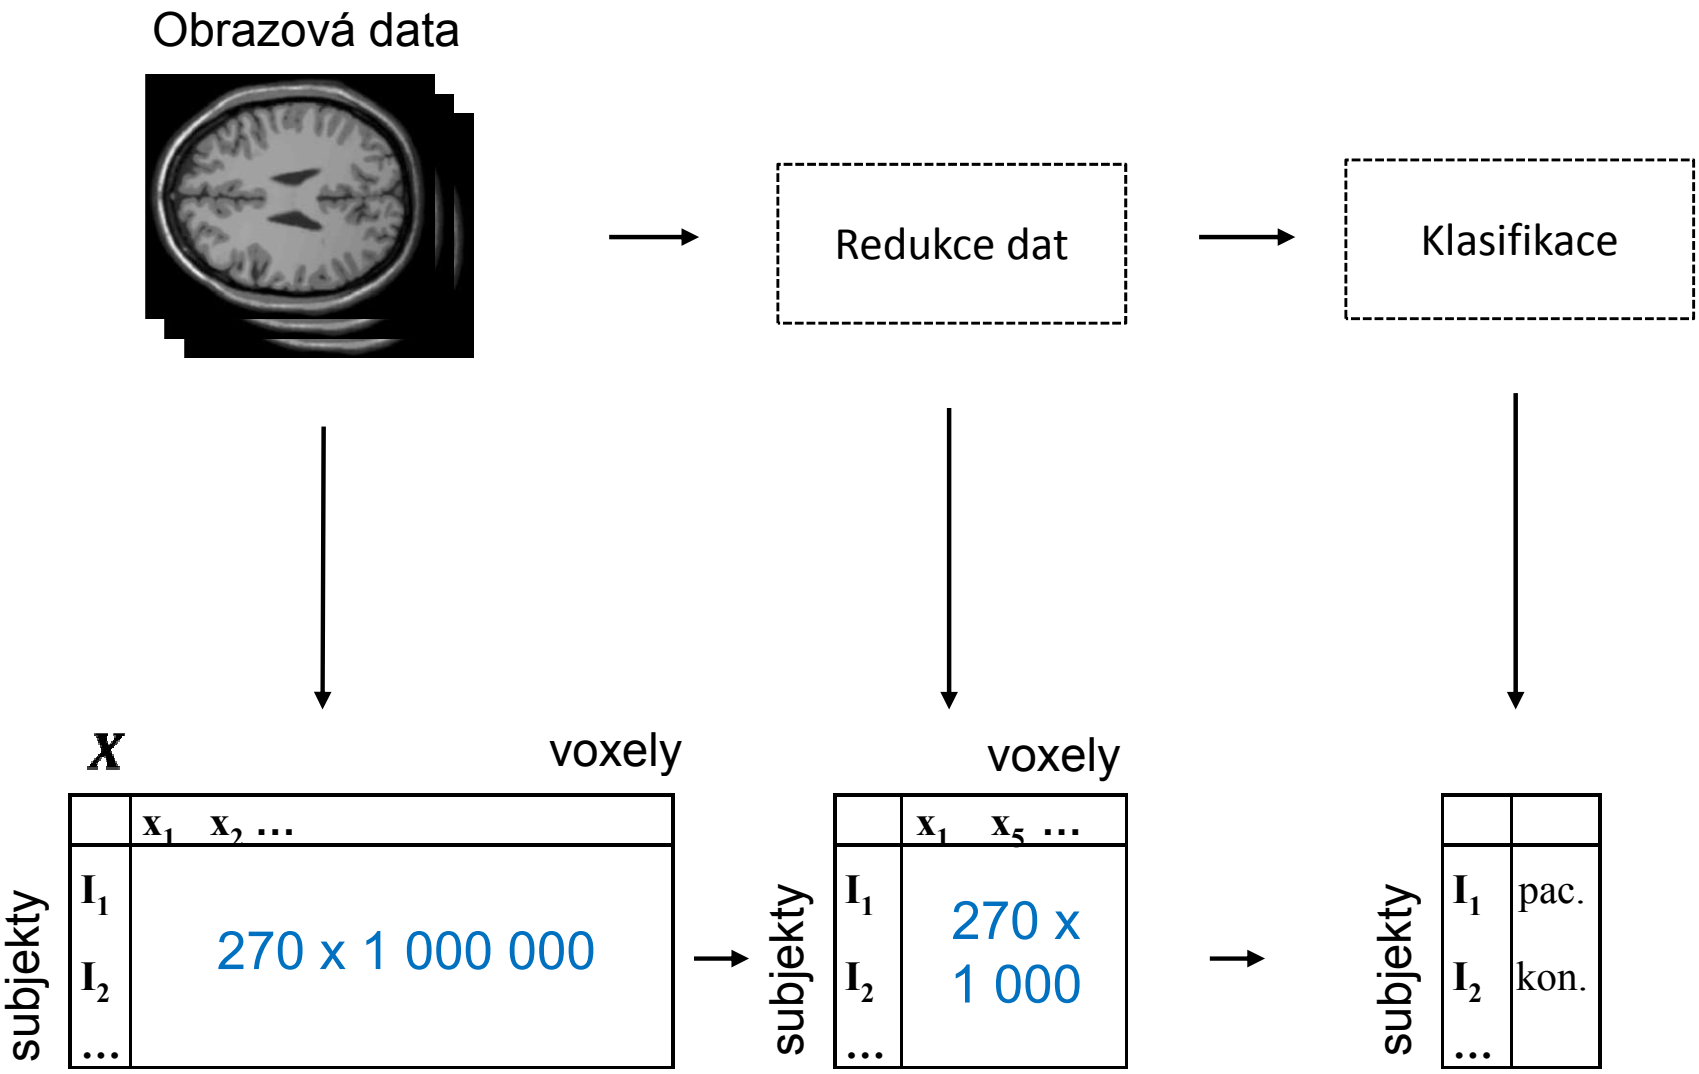

Proč používat redukci dat?

- zjednodušení další práce s daty
- možnost použití metod analýzy dat, které by na původní data nebylo možno použít
- umožnění vizualizace vícerozměrných dat – může být nápomocné k nalezení vztahů v datech či k jejich interpretaci
- redukce dat může být i cílem analýzy (např. identifikace oblastí mozku, kde se nejvíce liší od sebe liší skupiny subjektů)

Volba a výběr proměnných – úvod

- počáteční volba proměnných je z velké části empirická, vychází ze zkušeností získaných při empirické klasifikaci člověkem a závisí kromě rozboru podstaty problému i na technických (ekonomických) možnostech a schopnostech hodnoty proměnných určit
- kolik a jaké proměnné?
  - málo proměnných – možná nízká úspěšnost klasifikace či jiných následných analýz
  - moc proměnných – možná nepřiměřená pracnost, vysoké náklady

⇓

KOMPROMIS

(určit ty proměnné, jejichž hodnoty nesou nejvíce informace z hlediska řešené úlohy, tj. např. ty proměnné, kterou jsou nejefektivnější pro vytvoření co nejoddělenějších klasifikačních tříd)

Zásady pro volbu proměnných I

- výběr proměnných s minimálním rozptylem uvnitř tříd

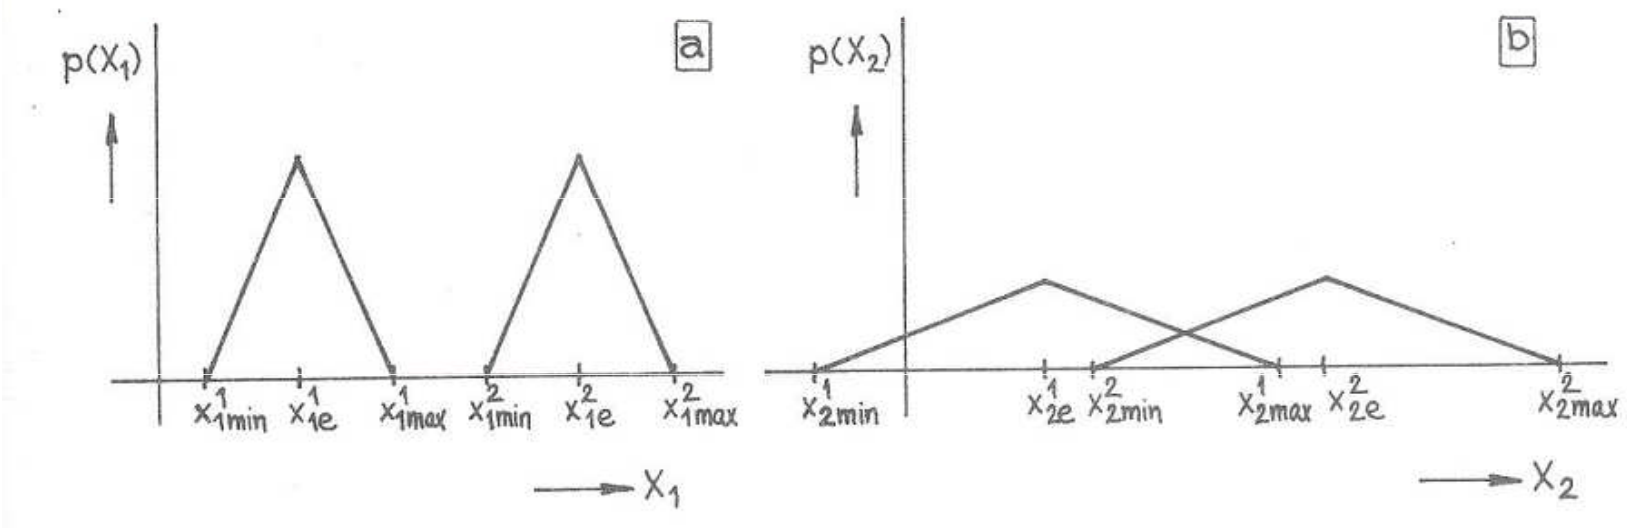

- výběr proměnných s maximální vzdáleností mezi třídami

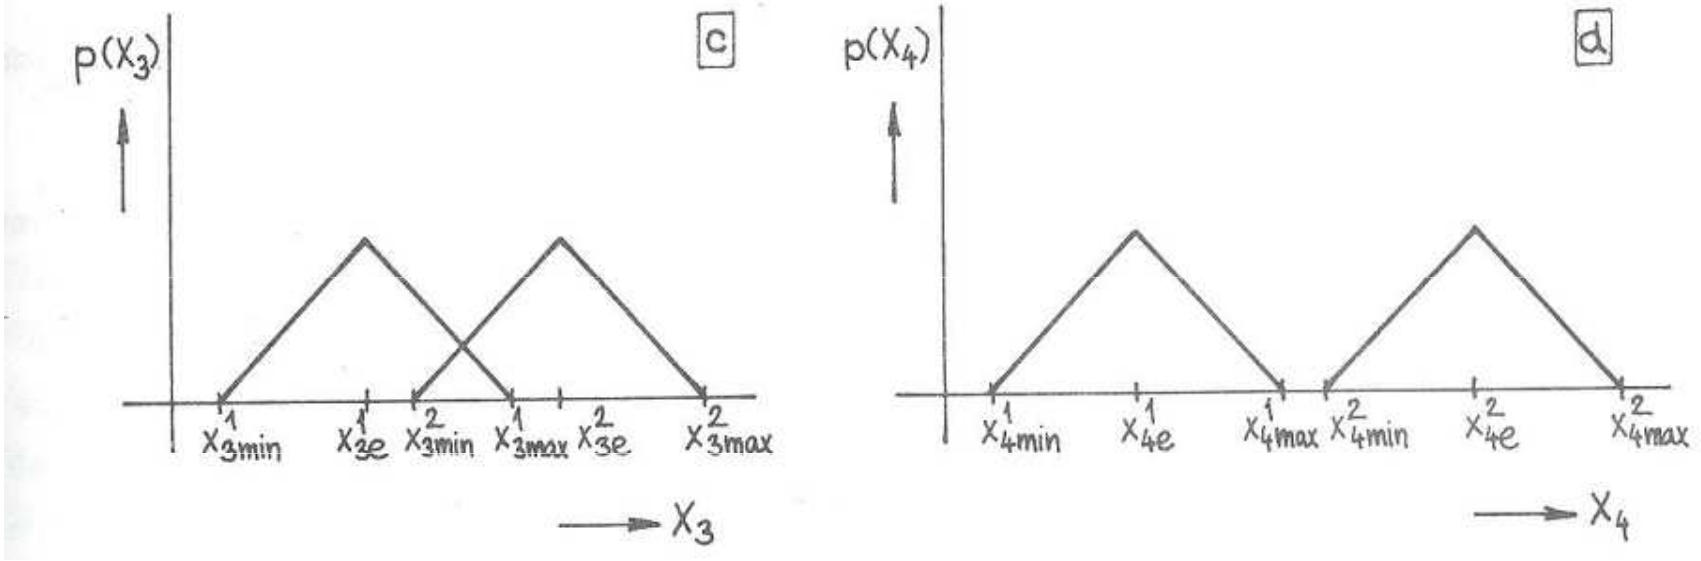

Zásady pro volbu proměnných II

- výběr vzájemně nekorelovaných proměnných
  - pokud jsou hodnoty jedné proměnné závislé na hodnotách druhé proměnné, pak použití obou těchto proměnných nepřináší žádnou další informaci – stačí jedna z nich, jedno která

- výběr proměnných invariantních vůči deformacím
  - volba elementů formálního popisu závisí na vlastnostech původních i předzpracovaných dat a může ovlivňovat způsob předzpracování

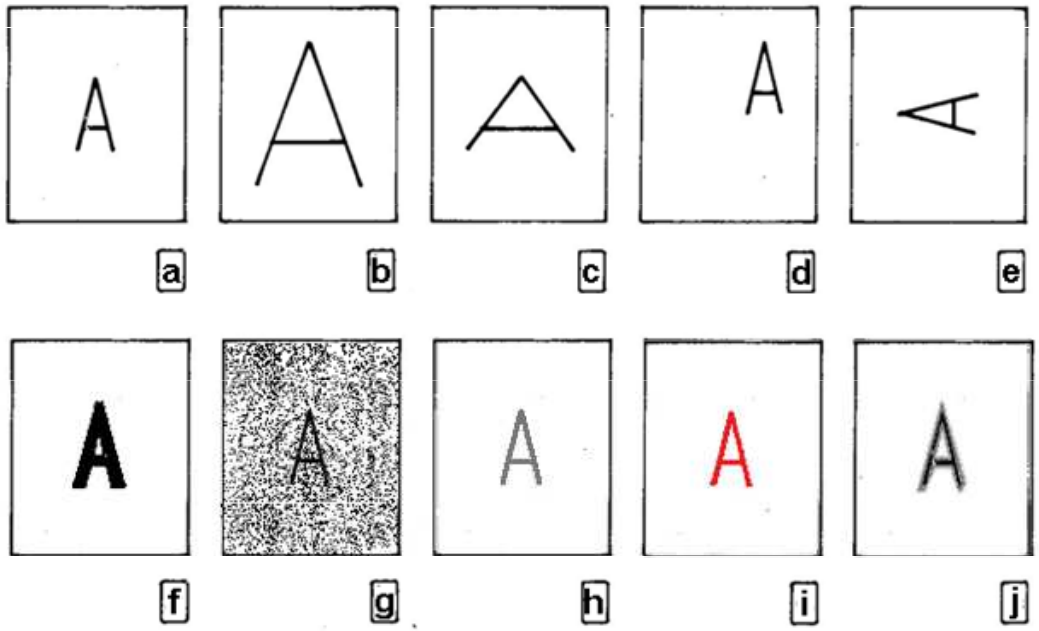

Selekce a extrakce proměnných

Selekce a extrakce proměnných

- popis objektu původně reprezentovaný *p* rozměrným vektorem se snažíme vyjádřit vektorem *m* rozměrným tak, aby množství diskriminační informace obsažené v původním vektoru bylo v co největší míře zachováno
- dva principiálně různé způsoby:

1. **selekce** – výběr těch proměnných, které přispívají k separabilitě klasifikačních tříd nejvíce

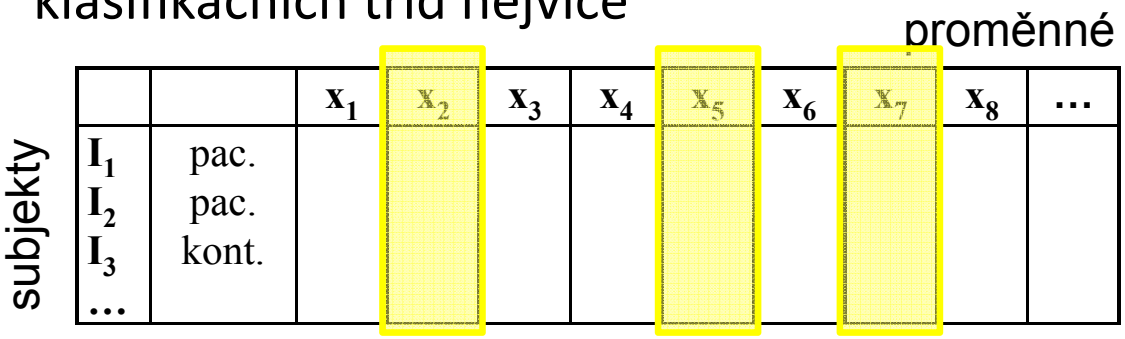

2. **extrakce** – transformace původních proměnných na menší počet jiných proměnných (které zpravidla nelze přímo měřit a často nemají zcela jasnou interpretaci)

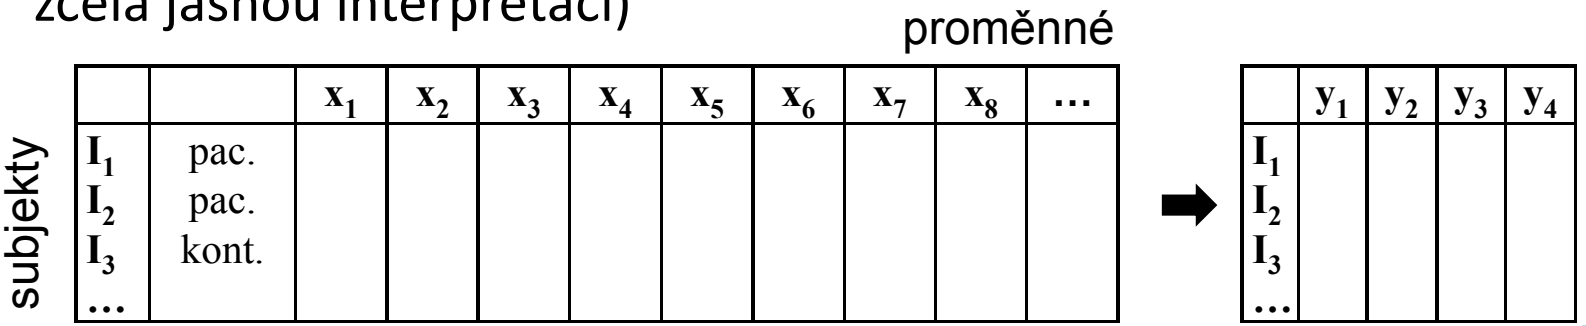

Selekce proměnných

- cílem je výběr proměnných, které jsou nejužitečnější pro další analýzu (např. při klasifikaci výběr takových proměnných, které nejlépe od sebe dokáží oddělit skupiny subjektů/objektů)

- metod selekce je velké množství, nejpoužívanější metody jsou:
  - výběr proměnných na základě statistických testů
  - výběr oblastí mozku (ROI) podle atlasu
  - algoritmy sekvenční selekce (dopředné či zpětné nebo algoritmus plus p mínus q)

Výběr proměnných na základě statistických testů

Princip: Výběr statisticky významných proměnných pomocí dvouvýběrového t-testu či Mannova-Whitneyova testu.

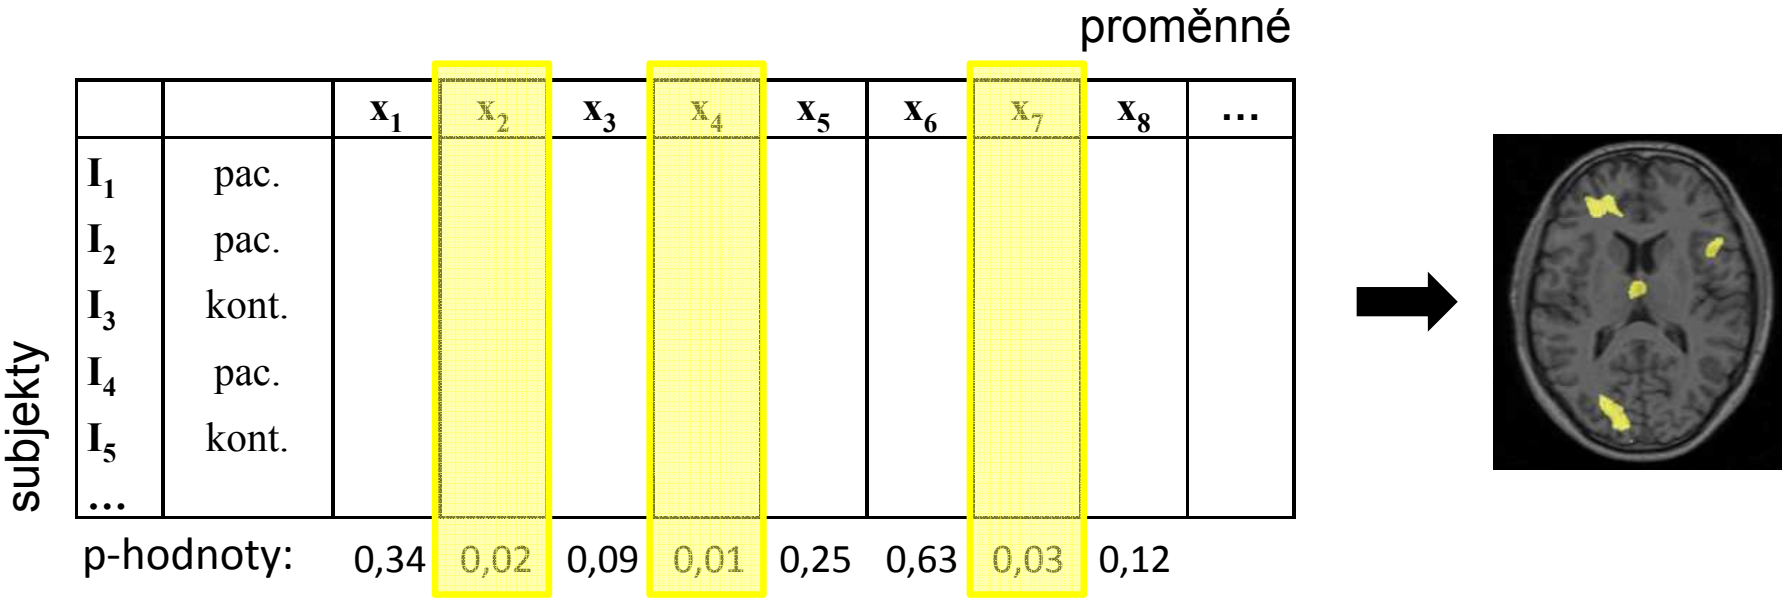

Výhody:

+ rychlé
+ u obrazů mozku výhodou, že je analýza provedena na celém mozku

Nevýhody:

- jednorozměrná metoda (výběr proměnných bez ohledu na ostatní proměnné)
- potřeba použít metody korekce pro mnohonásobné testování (např. FDR)

Výběr oblastí mozku (ROI) podle atlasu

Princip: Výběr oblastí mozku s využitím atlasu mozku podle expertní znalosti daného onemocnění (tzn. výběr oblasti postižené danou nemocí).

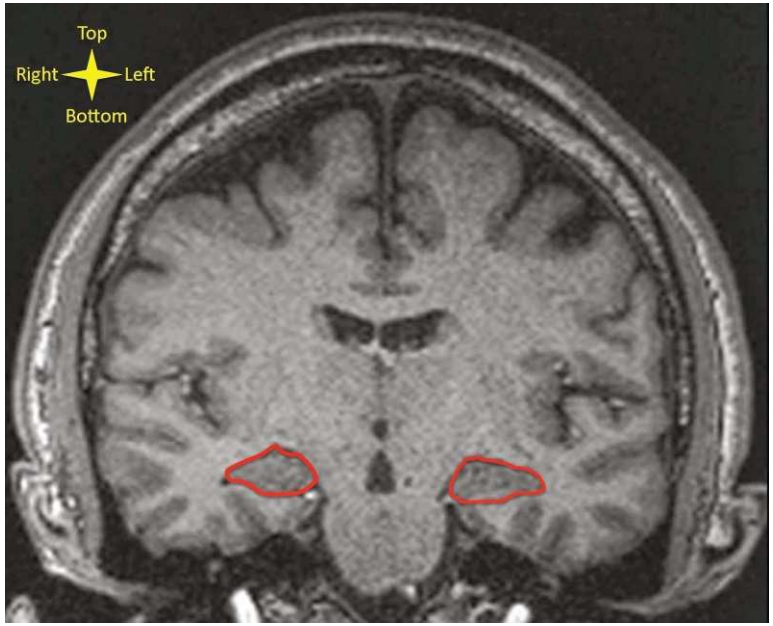

Výhody:

+ anatomicky/funkčně relevantní – snadnější interpretace
+ zpravidla rychlé

Nevýhody:

- ne vždy dopředu víme, která z oblastí je vhodná pro odlišení skupin osob
- některá onemocnění postihují celý mozek (např. schizofrenie)

Algoritmy sekvenční selekce

- algoritmus sekvenční dopředné selekce:
  - algoritmus začíná s prázdnou množinou, do které se vloží proměnná s nejlepší hodnotou selekčního kritéria
  - v každém následujícím kroku se přidá ta proměnná, která s dříve vybranými veličinami dosáhla nejlepší hodnoty kritéria
- algoritmus sekvenční zpětné selekce:
  - algoritmus začíná s množinou všech proměnných
  - v každém následujícím kroku se eliminuje ta proměnná, která způsobuje nejmenší pokles kriteriální funkce

Výhody : + dopředný algoritmus je výpočetně jednodušší, protože pracuje maximálně v n-rozměrném prostoru

+ zpětný algoritmus umožňuje průběžně sledovat množství ztracené informace

Nevýhody : - dopředná selekce – nelze vyloučit ty veličiny, které se staly nadbytečné po přiřazení dalších veličin

- zpětná selekce – neexistuje možnost opravy při neoptimálním vyloučení kterékoliv proměnné

- algoritmus plus p mínus q:
  - po přidání p veličin se q veličin odstraní;
  - proces probíhá, dokud se nedosáhne požadovaného počtu příznaků

Extrakce proměnných

- jednou z možných přístupů redukce dat
- transformace původních proměnných na menší počet jiných proměnných $\Rightarrow$ tzn. hledání (optimálního) zobrazení Z, které transformuje původní *p*-rozměrný prostor (obraz) na prostor (obraz) *m*-rozměrný ($p \geq m$)
- pro snadnější řešitelnost hledáme zobrazení Z v oboru lineárních zobrazení
- metody extrakce proměnných:
  - analýza hlavních komponent (PCA)
  - faktorová analýza (FA)
  - analýza nezávislých komponent (ICA)
  - korespondenční analýza (CA)
  - vícerozměrné škálování (MDS)
  - redundanční analýza (RDA)
  - kanonická korelační analýza (CCorA)
  - manifold learning metody (LLE, Isomap atd.)
  - metoda parciálních nejmenších čtverců (PLS)
- metody extrakce proměnných často nazývány jako metody ordinační analýzy

Ordinační analýza dat = pohled ze správného úhlu

- Vícerozměrná analýza nám pomáhá nalézt v x-dimenzionálním prostoru nejvhodnější pohled na data poskytující maximum informací o analyzovaných objektech

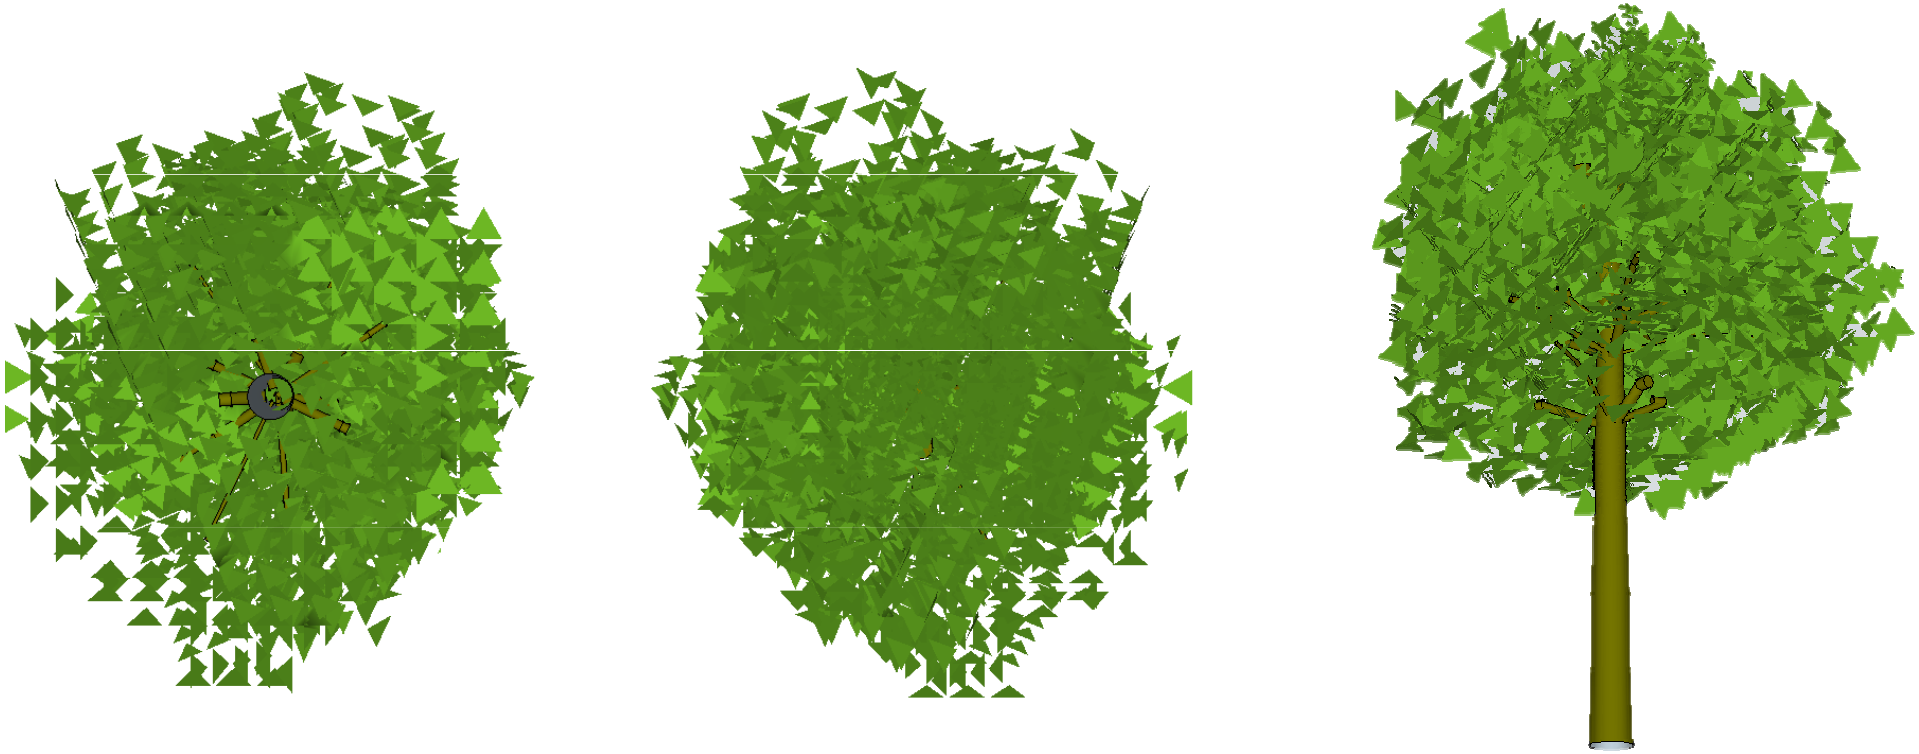

Všechny obrázky ukazují stejný objekt z různých úhlů v 3D prostoru.

Obecný princip redukce dimenzionality dat pomocí extrakce

- V převážné většině případů existují mezi dimenzemi korelační vztahy, tedy dimenze se navzájem vysvětlují a pro popis kompletní informace v datech není třeba všech dimenzí vstupního souboru
- Všechny tzv. ordinační metody využívají principu identifikace korelovaných dimenzí a jejich sloučení do souhrnných nových dimenzí zastupujících několik dimenzí vstupního souboru
- Pokud mezi dimenzemi vstupního souboru neexistují korelace, nemá smysl hledat zjednodušení vícerozměrné struktury takovéhoto souboru !!!

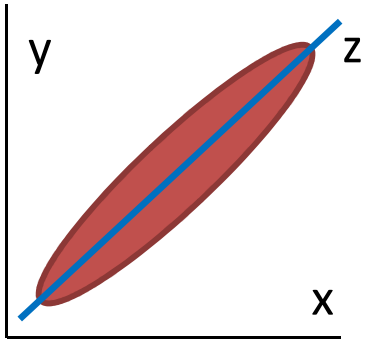

Jednoznačný vztah dimenzí x a y umožňuje jejich nahrazení jedinou novou dimenzí z

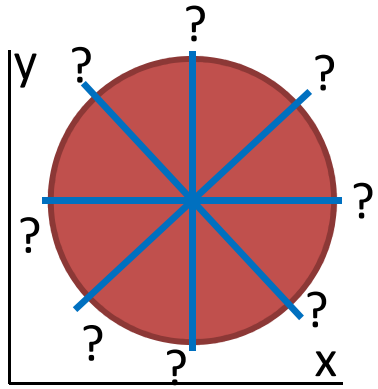

V případě neexistence vztahu mezi x a y nemá smysl definovat nové dimenze – nepřináší žádnou novou informaci oproti x a y

Korelace jako princip výpočtu vícerozměrných analýz

- Kovariance a Pearsonova korelace je základem analýzy hlavních komponent, faktorové analýzy i dalších vícerozměrných analýz pracujících s lineární závislostí proměnných
- Předpokladem výpočtu kovariance a Pearsonovy korelace je:
  - Normalita dat v obou dimenzích
  - Linearita vztahu proměnných
- Pro vícerozměrné analýzy je nejzávažnějším problémem přítomnost odlehlých hodnot

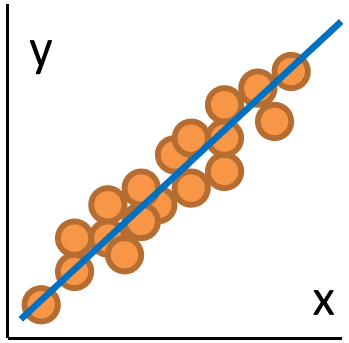

Lineární vztah – bezproblémové použití Pearsonovy korelace

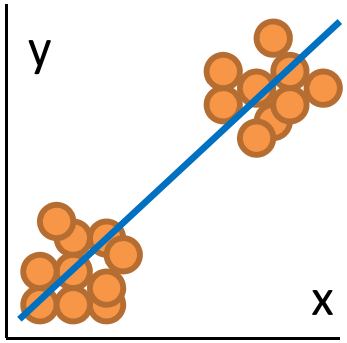

Korelace je dána 2 skupinami hodnot – vede k identifikaci skupin objektů v datech

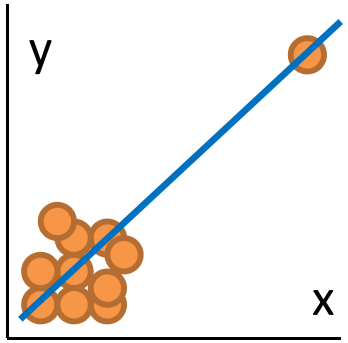

Korelace je dána odlehlou hodnotu – analýza popisuje pouze vliv odlehlé hodnoty

Typy ordinační analýzy

- Ordinačních analýz existuje celá řada, některé jsou spjaty s konkrétními metrikami vzdáleností/podobností
- V přehledu jsou uvedeny pouze základní typy analýz, nikoliv jejich různé kombinace hodnotící vztahy dvou a více sad proměnných (CCA, kanonická korelace, RDA, co-coordinate analysis, co-inertia analysis, diskriminační analýza apod.)

Typ analýzy	Vstupní data	Metrika
Analýza hlavních komponent (PCA)	NxP matice	Korelace, kovariance, Euklidovská
Faktorová analýza (FA)	NxP matice	Korelace, kovariance, Euklidovská
Analýza nezávislých komponent (ICA)	NxP matice	Korelace, kovariance, Euklidovská
Korespondenční analýza (CA)	NxP matice	Chi-square vzdálenost
Analýza hlavních koordinát (PCoA)	Asoc. matice	libovolná
Nemetrické mnohorozměrné škálování (MDS)	Asoc. matice	libovolná

Analýza hlavních komponent (PCA)

Analýza hlavních komponent

- anglicky Principal Component Analysis (PCA)
- snaha redukovat počet proměnných nalezením nových latentních proměnných (hlavních komponent) vysvětlujících co nejvíce variability původních proměnných
- nové proměnné (X_1, X_2) lineární kombinací původních proměnných (Y_1, Y_2)

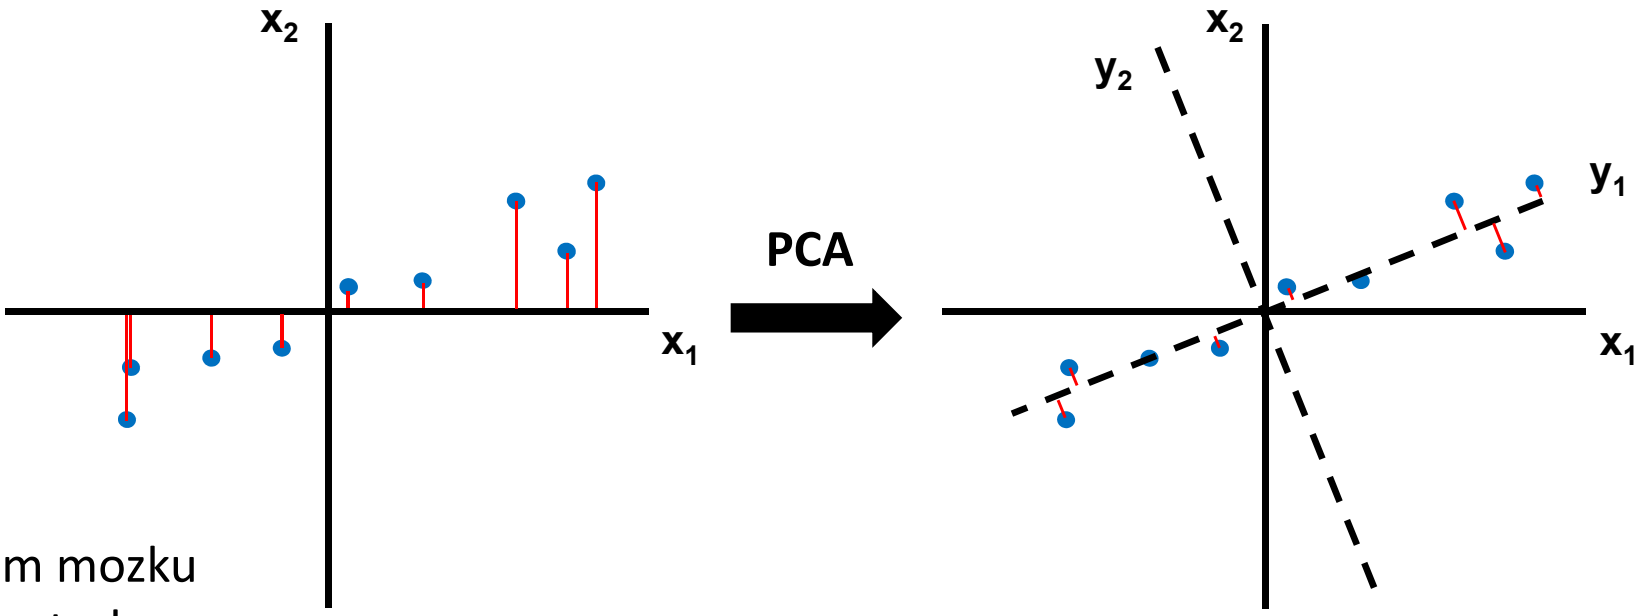

Výhody:

+ analýza na celém mozku
+ vícerozměrná metoda

Nevýhody:

- nevyužívá informaci o příslušnosti subjektů do skupin
- potřebné určit, kolik hlavních komponent se použije pro transformaci

Analýza hlavních komponent – cíle

- Popis a vizualizace vztahů mezi proměnnými
- Výběr neredundantních proměnných pro další analýzy
- Vytvoření zástupných faktorových os pro použití v dalších analýzách
- Identifikace shluků v datech spjatých s variabilitou dat
- Identifikace vícerozměrně odlehlých objektů

Analýza hlavních komponent – předpoklady

- vstupem do analýzy datová matice *n* x *p* obsahující kvantitativní proměnné (s normálním rozdělením)
- předpoklady obdobné jako při výpočtu korelací a kovariancí:
  - nepřítomnost odlehlých hodnot (s výjimkou situace, kdy analýzu provádíme za účelem identifikace odlehlých hodnot)
  - nepřítomnost více skupin objektů (s výjimkou situace, kdy analýzu provádíme za účelem detekce přirozeně existujících shluků spjatých s největší variabilitou souboru)
- datový soubor by měl mít více objektů než proměnných, pro získání stabilních výsledků se doporučuje alespoň 10x tolik objektů než proměnných, ideální je 40-60x více objektů než proměnných

Analýza hlavních komponent – volba asociační matice

- **autokorelační matice** – data nejsou nijak upravena (zohledňována průměrná hodnota i rozptyl původních dat)
- **kovarianční (disperzní) matice** – data centrována (od každé příznakové proměnné odečtena její střední hodnota) – zohledňován rozptyl původních dat
- **matice korelačních koeficientů** – data standardizována (odečtení středních hodnot a podělení směrodatnými odchylkami) – použití pokud mají proměnné různá měřítka
- **každou úpravou původních dat ale přicházíme o určitou informaci !!!**

Analýza hlavních komponent – volba asociační matice

- s jakými daty PCA pracuje v případě použití různých asociačních matic:

původní data

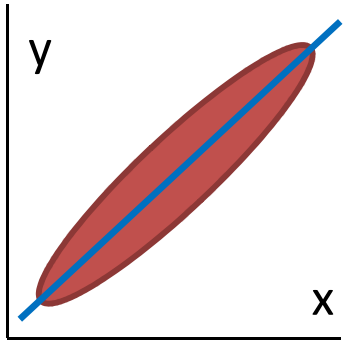

autokorelační matice
(data nijak neupravována)

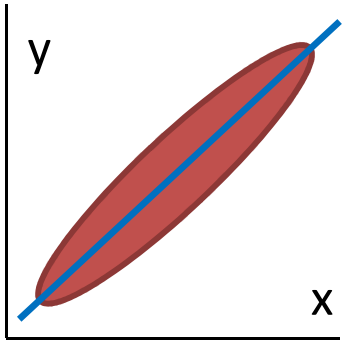

kovarianční matice
(odečten průměr)

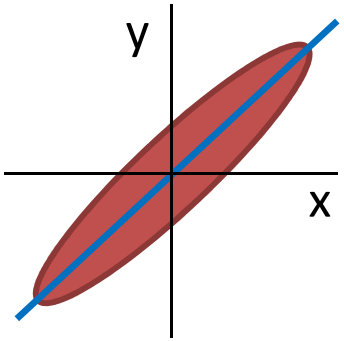

matice korelačních koeficientů
(odečten průměr a podělení SD)

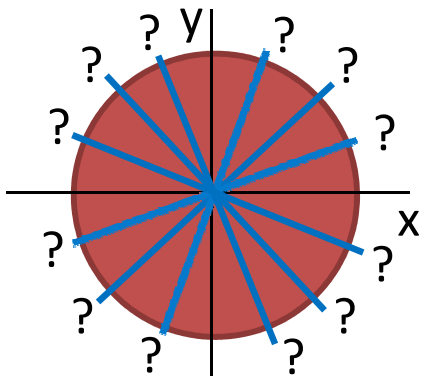

Analýza hlavních komponent – postup

1. Volba asociační matice (autokorelační, kovarianční nebo kor. koeficientů)
2. Výpočet vlastních čísel a vlastních vektorů asociační matice:
   - vlastní vektory definují směr nových faktorových os (hlavních komponent) v prostoru
   - vlastní čísla odrážejí variabilitu vysvětlenou příslušnou komponentou
3. Seřazení vlastních vektorů podle hodnot jim odpovídajících vlastních čísel (sestupně)
4. Výběr prvních *m* komponent vyčerpávajících nejvíce variability původních dat

Identifikace optimálního počtu hlavních komponent pro další analýzu

- pokud je cílem ordinační analýzy vizualizace dat, snažíme se vybrat 2-3 komponenty
- pokud je cílem ordinační analýzy výběr menšího počtu dimenzí pro další analýzu, můžeme ponechat více komponent (např. u analýzy obrazů MRI je úspěchem redukce z milionu voxelů na desítky)

- kritéria pro výběr počtu komponent:

1. Kaiser Guttmanovo kritérium:
   - pro další analýzu jsou vybrány osy s vlastním číslem >1 (při analýze matice korelačních koeficientů) nebo větším než průměrná hodnota vlastních čísel (při analýze kovarianční matice)
   - logika je vybírat osy, které přispívají k vysvětlení variability dat více, než připadá rovnoměrným rozdělením variability
2. Sutinový graf (scree plot)
   - grafický nástroj hledající zlom ve vztahu počtu os a vyčerpané variability
3. Sheppardův diagram
   - grafická analýza vztahu mezi vzdálenostmi objektů v původním prostoru a redukovaném prostoru o daném počtu dimenzí

Sutinový graf (scree plot)

Zlom ve vztahu mezi počtem vlastních čísel a jimi vyčerpanou variabilitou – pro další analýzu použity první dvě faktorové osy

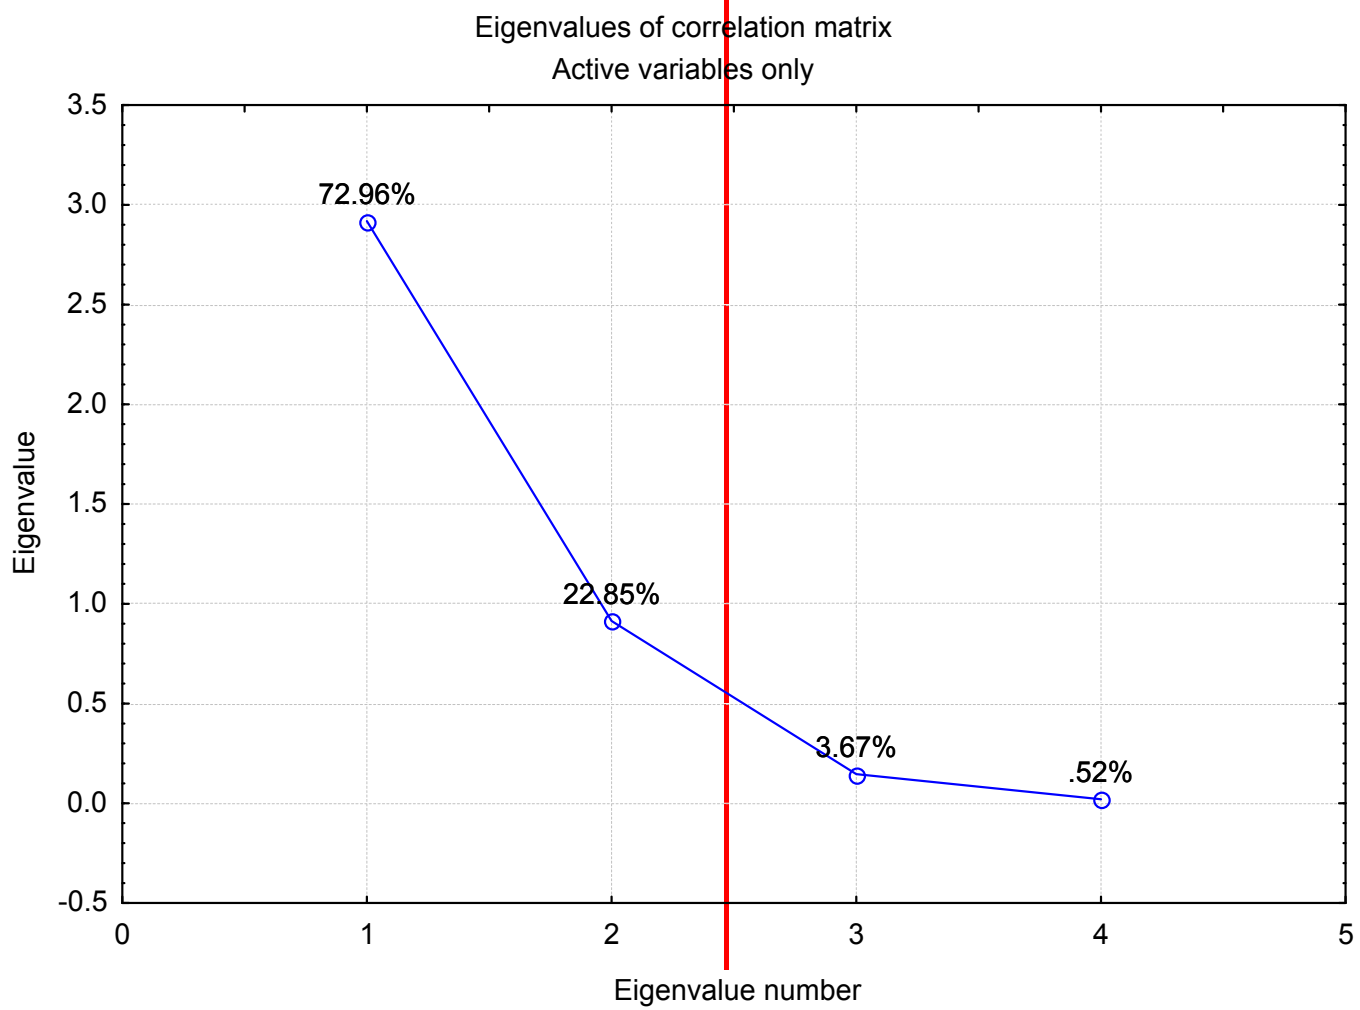

Sheppardův diagram

- Vztahuje vzdálenosti v prostoru původních proměnných ke vzdálenostem v prostoru vytvořeném PCA
- Je třeba brát ohled na typ PCA (korelace vs. kovariance)
- Obecná metoda určení optimálního počtu dimenzí v ordinační analýze (třeba respektovat použitou asociační metriku)

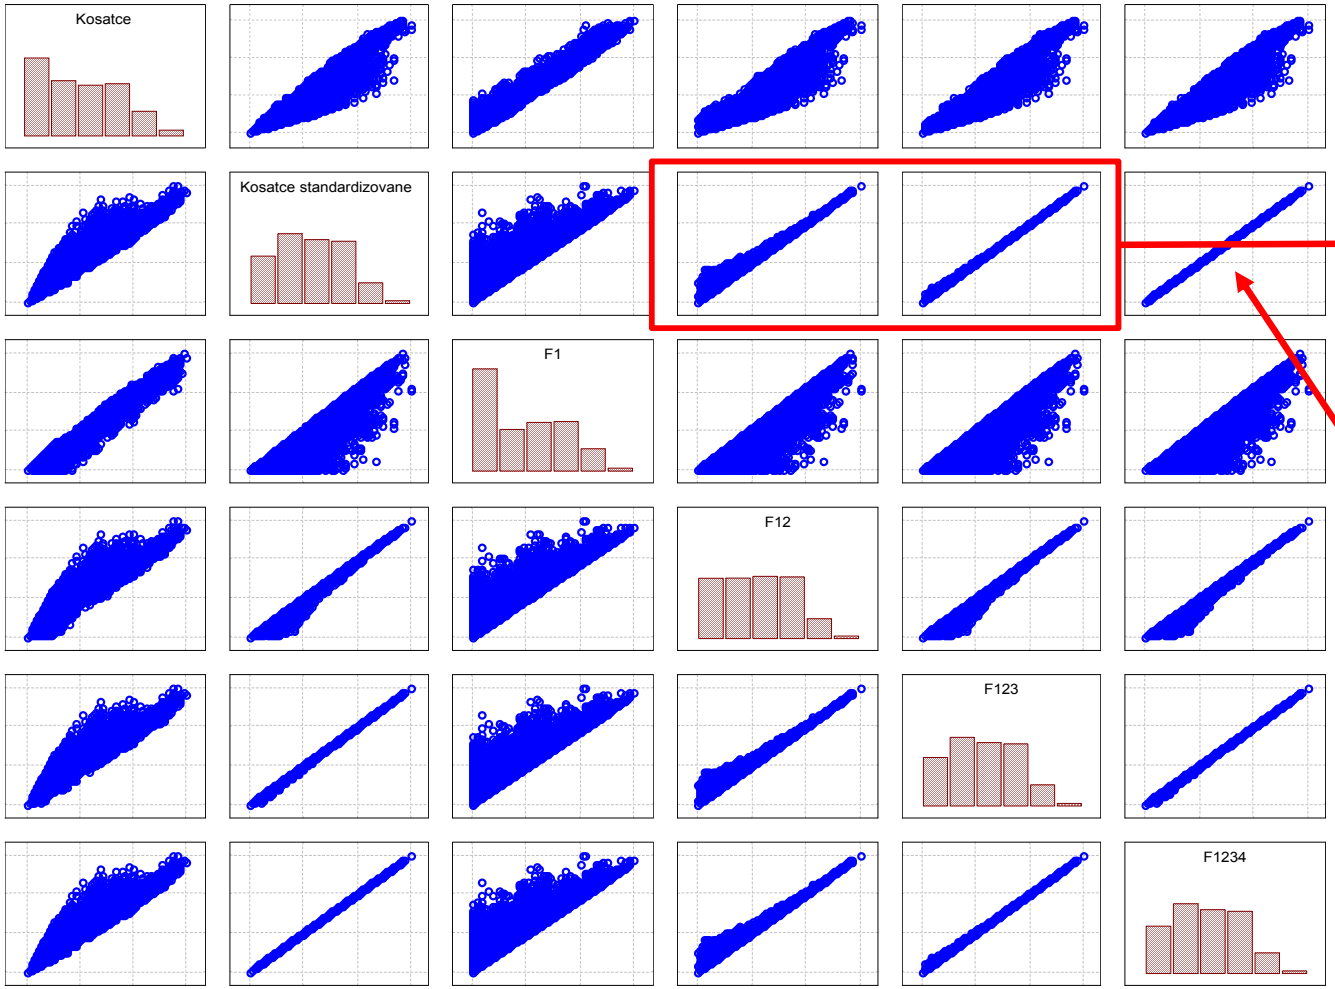

Za optimální z hlediska zachování vzdáleností objektů lze považovat dvě nebo tři dimenze

Při použití všech dimenzí jsou vzdálenosti perfektně zachovány

PCA – geometrická interpretace

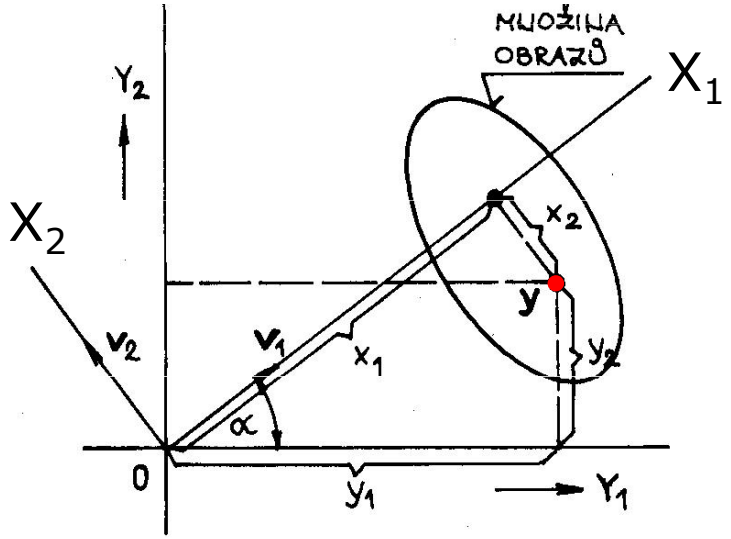

použití obou hlavních komponent

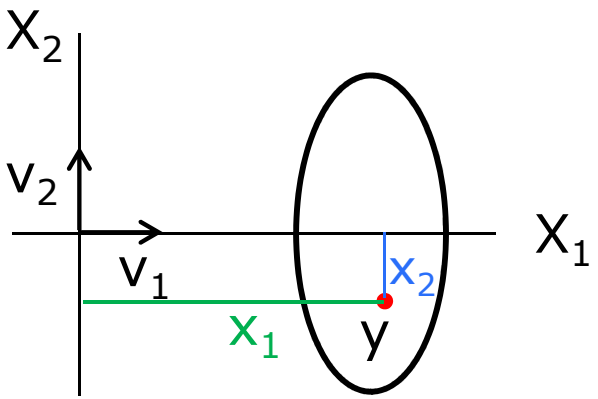

použití 1. hlavní komponenty

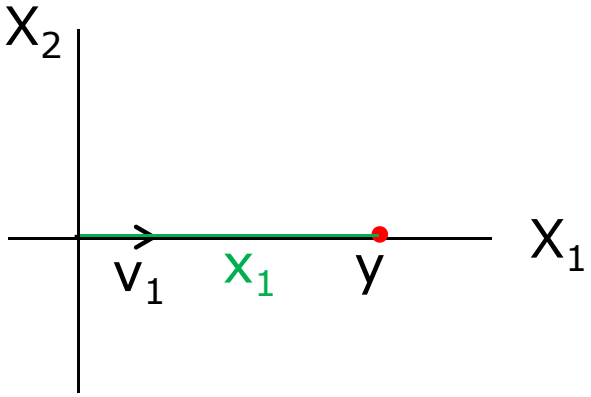

použití 2. hlavní komponenty

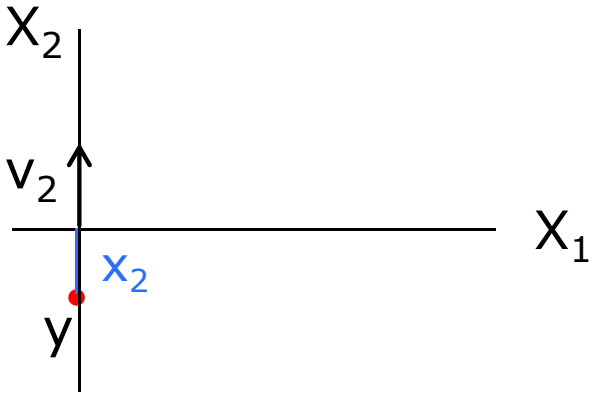

PCA – rozdělení do tříd

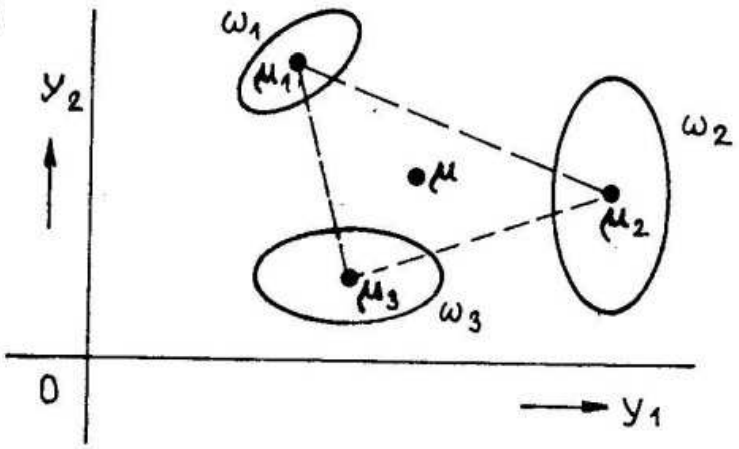

odečtení průměru každé skupiny zvlášť

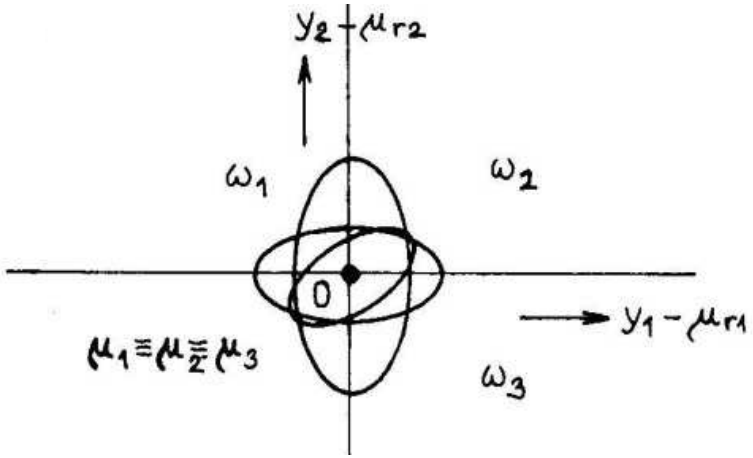

→ není vhodné

odečtení celkového průměru

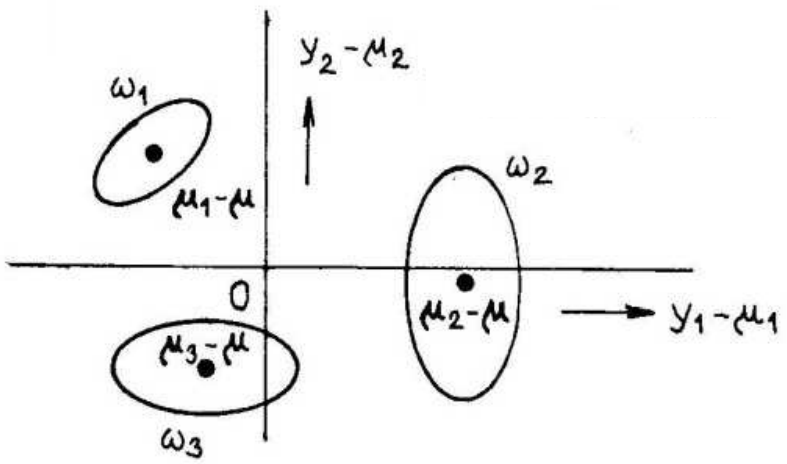

→ je vhodné

PCA a klasifikace I

- PCA často nebývá vhodnou metodou redukce dat před klasifikací

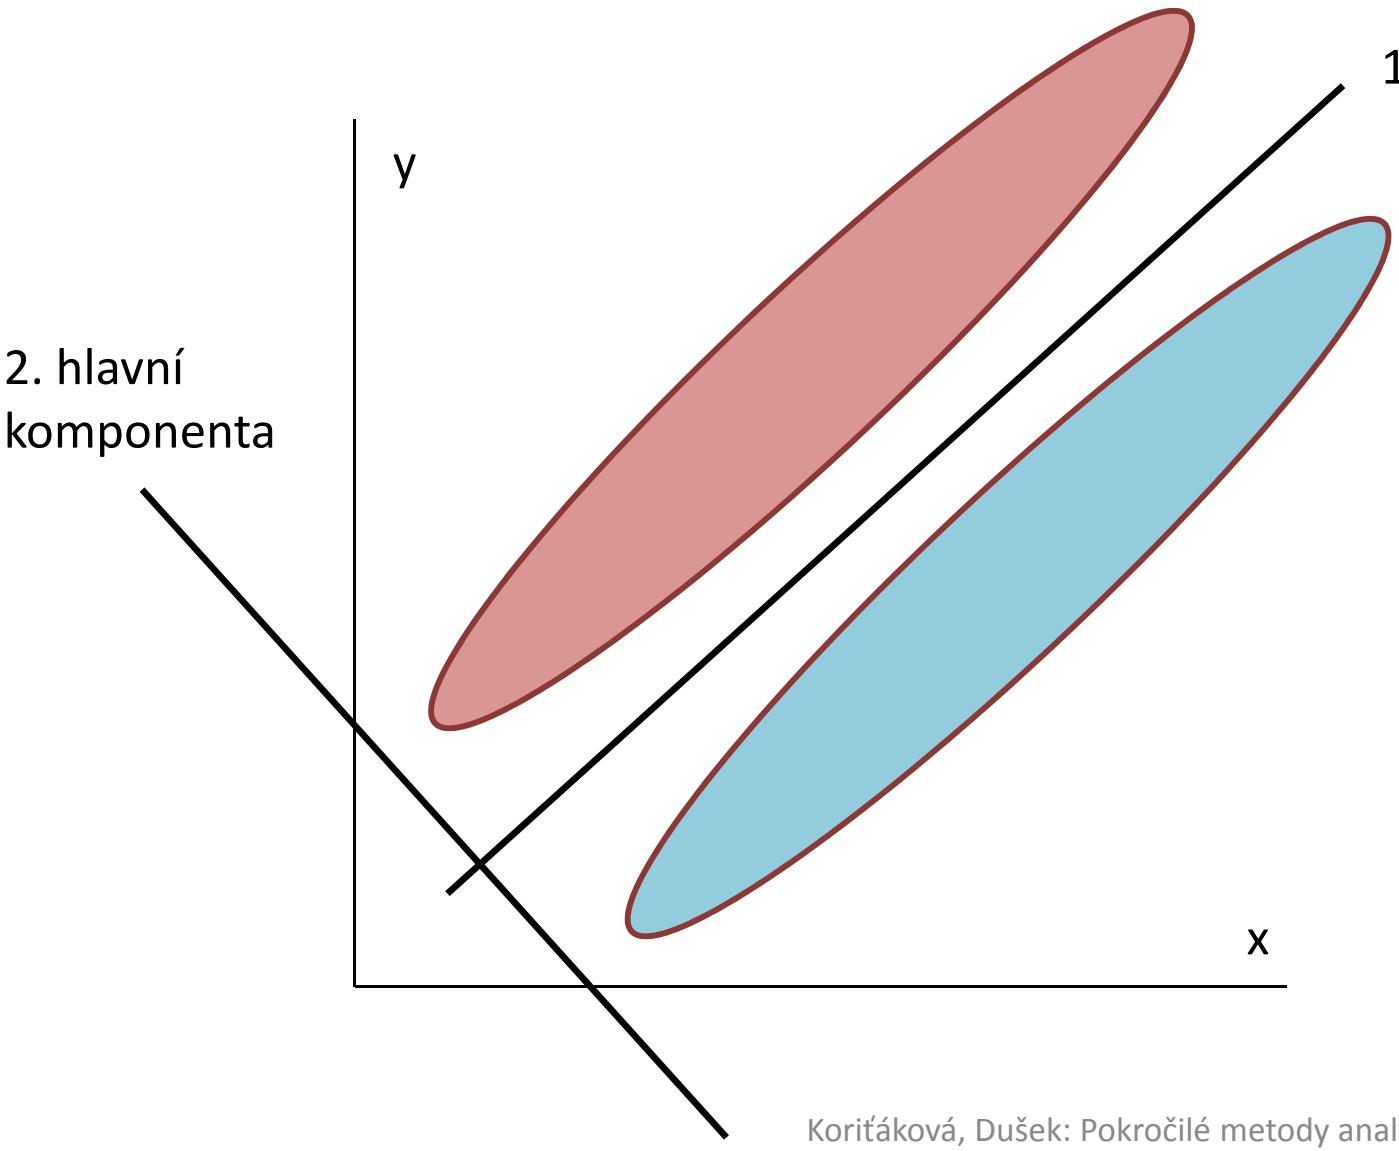

Pro klasifikaci vhodnější 2. HK, přestože vyčerpává méně variability!

PCA a klasifikace II

Když hlavní komponenta vyčerpává hodně variability, neznamená to, že musí rovněž dobře klasifikovat

vysoká korelace mezi proměnnými 1 a 2
- způsobená tím, že se skupiny od sebe hodně liší

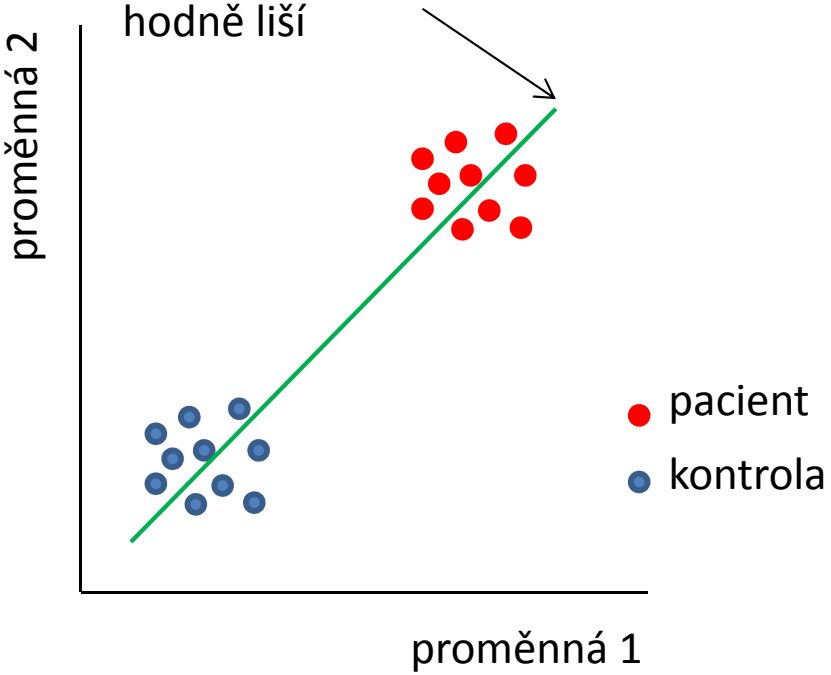

→ v tomto případě obě proměnné budou korelovat s první hlavní komponentou a dokáží dobře diskriminovat pacienty a kontroly

vysoká korelace mezi proměnnými 1 a 2
- skupiny se ale od sebe neliší

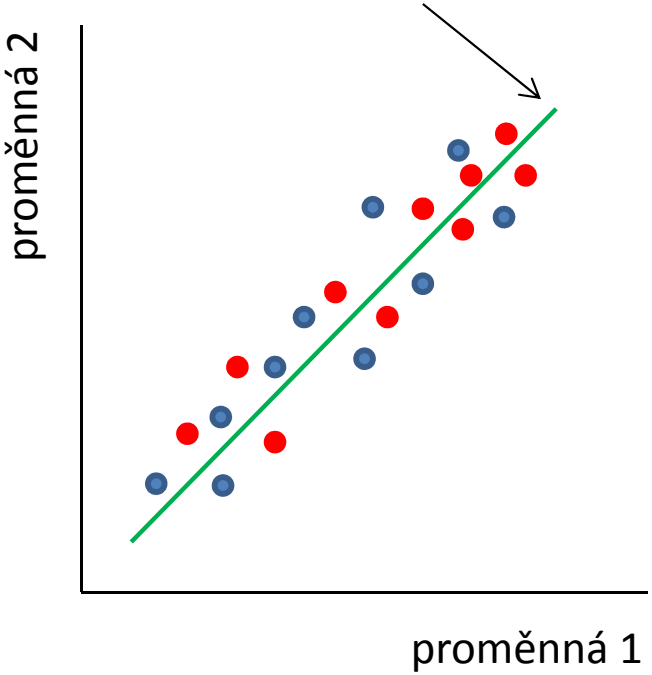

→ v tomto případě obě proměnné budou také korelovat s první hlavní komponentou, ale nedokáží diskriminovat pacienty a kontroly

PCA – rozšiřující poznatky I

Výpočet PCA, když je počet proměnných mnohem větší než počet subjektů:

- 1. způsob: iterativní postupný výpočet vlastních vektorů a vlastních čísel
- 2. způsob: pPCA - výpočet vlastních vektorů $\mathbf{v}_i$ „velké“ kovarianční matice (proměnných) $\mathbf{X}^T\mathbf{X}_{(p,p)}$ z vlastních vektorů $\mathbf{w}_i$ „malé“ kovarianční matice (subjektů) $\mathbf{X}\mathbf{X}^T_{(n,n)}$ pomocí: $\mathbf{v}_i = \frac{\mathbf{X}^T\mathbf{w}_i}{\sqrt{\lambda_i(n-1)}}$

Datová matice:

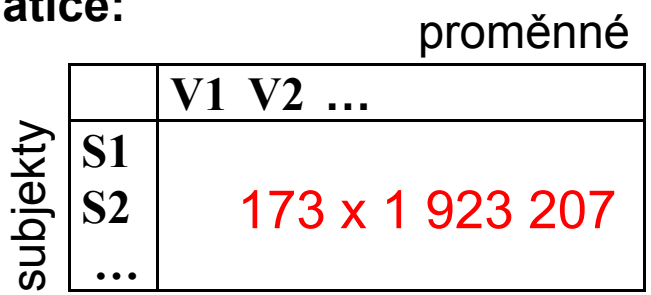

Kovarianční matice subjektů:

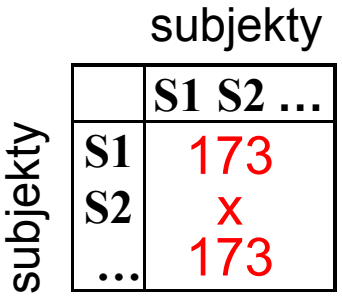

Kovarianční matice proměnných:

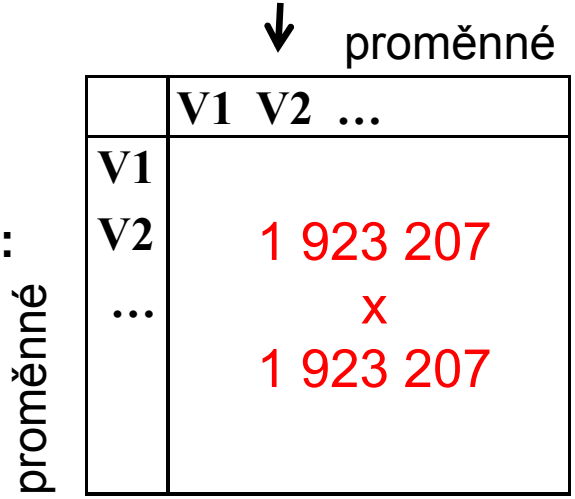

PCA – rozšiřující poznatky II

Souvislost se singulárním rozkladem (SVD – Singular Value Decomposition):

$$\mathbf{X}_{(n,p)} = \mathbf{U}_{(n,k)}\Gamma_{(k,k)}\mathbf{V}^{\mathrm{T}}_{(k,p)}$$

- matice **U** a **V** jsou ortogonální a normované (ortonormální)
- matice **U** složena z vlastních (charakteristických) vektorů matice $\mathbf{XX}^{\mathrm{T}}_{(n,n)}$
- matice **V** z vlastních vektorů matice $\mathbf{X}^{\mathrm{T}}\mathbf{X}_{(p,p)}$
- Matice **Γ** je typu *k x k* a její diagonála je tvořena singulárními hodnotami, které jsou na hlavní diagonále uspořádány podle klesající velikosti a které jsou rovny odmocninám vlastních čísel matice $\mathbf{XX}^{\mathrm{T}}$ i $\mathbf{X}^{\mathrm{T}}\mathbf{X}$

PCA – příklad – řešení v Matlabu

- Zadání: Proveďte PCA na objemech 6 mozkových struktur u 833 subjektů.
- Řešení:

```
[num, txt, raw] = xlsread('Data_neuro.xlsx',1);
data = num(:,23:28); % vyber 6 promennych s objemy mozkovych struktur
[coeff,score,latent] = pca(data);
```

Souřadnice subjektů v novém prostoru

score

833x6 double

	1	2	3	4	5	6
1	-541.6758	322.0604	90.5446	94.2298	-249.6611	-27.3529
2	-306.1072	508.2459	-423.5306	-204.0785	-40.5948	-148.3389
3	218.0346	473.6196	192.8200	-163.2062	-82.3617	128.0769
4	-492.7048	535.5033	-267.8827	-74.2783	-56.0326	-351.3861
5	-346.3904	240.7737	-312.9827	-106.9215	-5.0059	32.8323
6	-123.1009	749.8831	-315.0017	-241.6806	63.2878	-46.0834
7	-1.1798e+03	76.8159	-150.7726	321.9671	-182.4523	162.2400
8	-321.2074	8.9410	-255.2537	151.7913	-36.5035	192.6580
9	-345.8090	464.1571	-374.4555	11.8603	-5.8649	91.6828
10	-1.4653e+03	697.7425	-380.2903	267.2337	-19.2383	-81.4055

hlavní komponenty jsou ve sloupcích (jsou seřazené podle vlastních čísel); v řádcích jsou subjekty

Matice vlastních vektorů

coeff

6x6 double

	1	2	3	4	5	6
1	-0.0355	0.8886	-0.0485	-0.1217	-0.3093	-0.3103
2	-0.0313	0.3748	-0.0956	0.2942	0.8661	0.1132
3	0.0010	0.1000	0.9870	0.1023	0.0218	0.0702
4	-0.0120	0.0560	-0.1046	0.9024	-0.3676	0.1903
5	-0.0231	0.2331	-0.0580	-0.2714	-0.1363	0.9217
6	0.9985	0.0493	-0.0083	0.0094	0.0086	0.0160

vlastní vektory jsou ve sloupcích (jsou seřazené podle vlastních čísel)

Vlastní čísla

latent

6x1 double

	1
1	4.0368e+05
2	1.3907e+05
3	7.0200e+04
4	4.1841e+04
5	4.0421e+04
6	3.2738e+04

PCA – příklad – řešení v softwaru R

- **Zadání:** Proveďte PCA na objemech 6 mozkových struktur u 833 subjektů.
- **Řešení:**

```
library(readxl)
data <- read_excel('Data_neuro.xlsx',sheet="data")
data <- data[,24:29]   # vyber 6 promennych s objemy mozkovych struktur
pca <- prcomp(data)   # vypocet PCA s kovariancni matici; tzn. pouzito defaulni
center=TRUE a scale=FALSE; pro m. korel. koef. – prcomp(data,scale=TRUE)
pca$sdev^2   # vlastni cisla
```

```
> pca$sdev^2
[1] 403676.97 139067.09  70200.25  41840.70  40421.08  32737.94
```

```
pca$rotation   # vlastni vektory (ve sloupcich, serazene podle vlastnich cisel)
```

```
> pca$rotation
                              PC1        PC2         PC3         PC4         PC5         PC6
Hippocampus_volume (mm3) -0.035459125 0.88861834 -0.048506362  0.121740139  0.309258675 -0.31029927
Amygdala_volume (mm3)    -0.031283533 0.37476563 -0.095616471 -0.294217081 -0.866059128  0.11317002
Thalamus_volume (mm3)     0.001035499 0.10003061  0.986981343 -0.102255212 -0.021806247  0.07020677
Pallidum_volume (mm3)    -0.012014730 0.05596007 -0.104571564 -0.902442907  0.367642426  0.19032801
Putamen_volume (mm3)     -0.023074151 0.23311937 -0.058031628  0.271419287  0.136348899  0.92168098
Nucl_caud_volume (mm3)    0.998542011 0.04925323 -0.008340823 -0.009374972 -0.008553979  0.01604185
```

```
pca$x   # hlavni komponenty (tj. souradnice subjektu v novem prostoru)
```

```
> pca$x
              PC1          PC2          PC3         PC4          PC5         PC6
[1,] -5.416758e+02  322.0603857   90.54458062  -94.2298142  249.66114452  -27.3528609
[2,] -3.061072e+02  508.2458732 -423.53056436  204.0784644   40.59484197 -148.3389455
[3,]  2.180346e+02  473.6196500  192.81995921  163.2061839   82.36173899  128.0769292
[4,] -4.927048e+02  535.5032528 -267.88271465   74.2783108   56.03257012 -351.3861289
[5,] -3.463904e+02  240.7736931 -312.98274680  106.9214737    5.00591406   32.8322655
```

PCA – příklad – řešení v softwaru Statistica I

- Zadání: Proveďte PCA na objemech 6 mozkových struktur u 833 subjektů.
- Řešení: Statistics – Multivariate Exploratory Techniques – Principal Components & Classification Analysis

vybrat proměnné

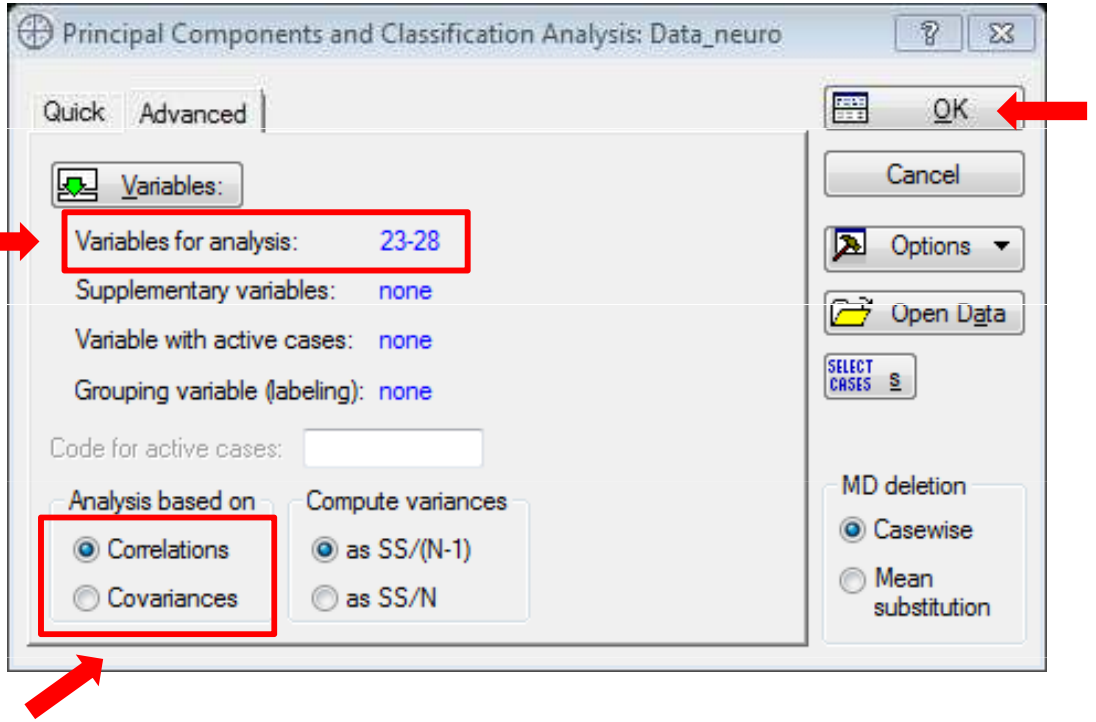

zvolit, zda se má počítat kovarianční či korelační matice

PCA – příklad – řešení v softwaru Statistica II

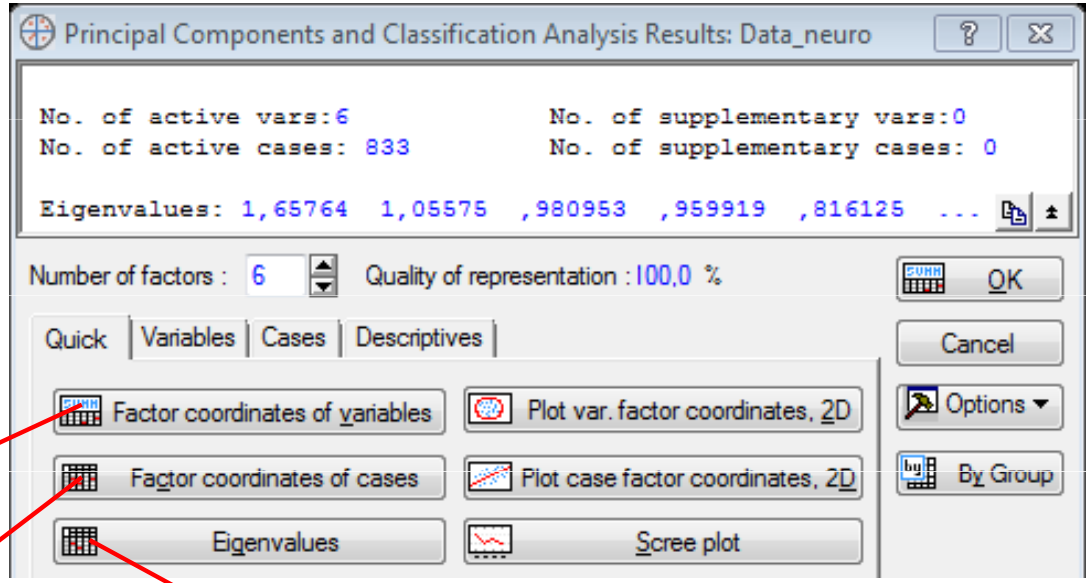

Matice vlastních vektorů

Factor coordinates of the variables, based on correlations (Data_neuro)

Variable	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5	Factor 6
Hippocampus_volume (mm3)	-22,5292	-331,381	12,852	-24,9019	-62,1764	-56,1444
Amygdala_volume (mm3)	-19,8762	-139,756	25,334	60,1821	174,1211	20,4766
Thalamus_volume (mm3)	0,6579	-37,303	-261,504	20,9163	4,3841	12,7030
Pallidum_volume (mm3)	-7,6336	-20,868	27,707	184,5947	-73,9145	34,4372
Putamen_volume (mm3)	-14,6603	-86,934	15,376	-55,5188	-27,4129	166,7655
Nucl_caud_volume (mm3)	634,4294	-18,367	2,210	1,9177	1,7198	2,9026

Souřadnice subjektů v novém prostoru

Factor coordinates of cases, based on covariances (Data_neuro)

Case	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5	Factor 6
1	-541,68	-322,060	-90,545	94,230	-249,661	-27,353
2	-306,11	-508,246	423,531	-204,078	-40,595	-148,339
3	218,03	-473,620	-192,820	-163,206	-82,362	128,077
4	-492,70	-535,503	267,883	-74,278	-56,033	-351,386
5	-346,39	-240,774	312,983	-106,921	-5,006	32,832
6	-123,10	-749,883	315,002	-241,681	63,288	-46,083
7	-1179,78	-76,816	150,773	321,967	-182,452	162,240
8	-321,21	-8,941	255,254	151,791	-36,504	192,658

Vlastní čísla

Eigenvalues of covariance ma
Active variables only

Value number	Eigenvalue	% Total variance
1	403677,0	55,45440
2	139067,1	19,10409
3	70200,2	9,64363
4	41840,7	5,74779
5	40421,1	5,55277
6	32737,9	4,49732

PCA – příklad – řešení v softwaru Statistica III

Normalizace vlastních vektorů:

- zkopírovat do Excelu („Copy with headers“)
- použití vzorce: =B3/ODMOCNINA(SUMA.ČTVERCŮ(B$3:B$8))

	A	B	C	D	E	F	G
1		Factor coordinates of the variables, based on correlations (Data_neuro)					
2	Variable	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5	Factor 6
3	Hippocamp	-22,5292	-331,381	12,852	-24,9019	-62,1764	-56,1444
4	Amygdala_	-19,8762	-139,756	25,334	60,1821	174,1211	20,4766
5	Thalamus_	0,6579	-37,303	-261,504	20,9163	4,3841	12,7030
6	Pallidum_v	-7,6336	-20,868	27,707	184,5947	-73,9145	34,4372
7	Putamen_v	-14,6603	-86,934	15,376	-55,5188	-27,4129	166,7655
8	Nucl_caud	634,4294	-18,367	2,210	1,9177	1,7198	2,9026
9							
10		-0,035459125	-0,88862	0,048506	-0,12174	-0,30926	-0,3103
11		-0,031283533	-0,37477	0,095616	0,294217	0,866059	0,11317
12		0,001035499	-0,10003	-0,98698	0,102255	0,021806	0,070207
13		-0,01201473	-0,05596	0,104572	0,902443	-0,36764	0,190328
14		-0,023074151	-0,23312	0,058032	-0,27142	-0,13635	0,921681
15		0,998542011	-0,04925	0,008341	0,009375	0,008554	0,016042

PCA – příklad – řešení v softwaru Statistica IV

Záložka Variables:

Factor & variable correlations

Plot var. factor coordinates, 2D

Variable	Factor-variable correlations (factor loadings), Factor 1	Factor 2	Factor 3
Hippocampus_volume (mm3)	-0,065550	-0,964180	0,037394
Amygdala_volume (mm3)	-0,084808	-0,596314	0,108095
Thalamus_volume (mm3)	0,002480	-0,140597	-0,985620
Pallidum_volume (mm3)	-0,037255	-0,101845	0,135217
Putamen_volume (mm3)	-0,073621	-0,436566	0,077214
Nucl_caud_volume (mm3)	0,999556	-0,028938	0,003482

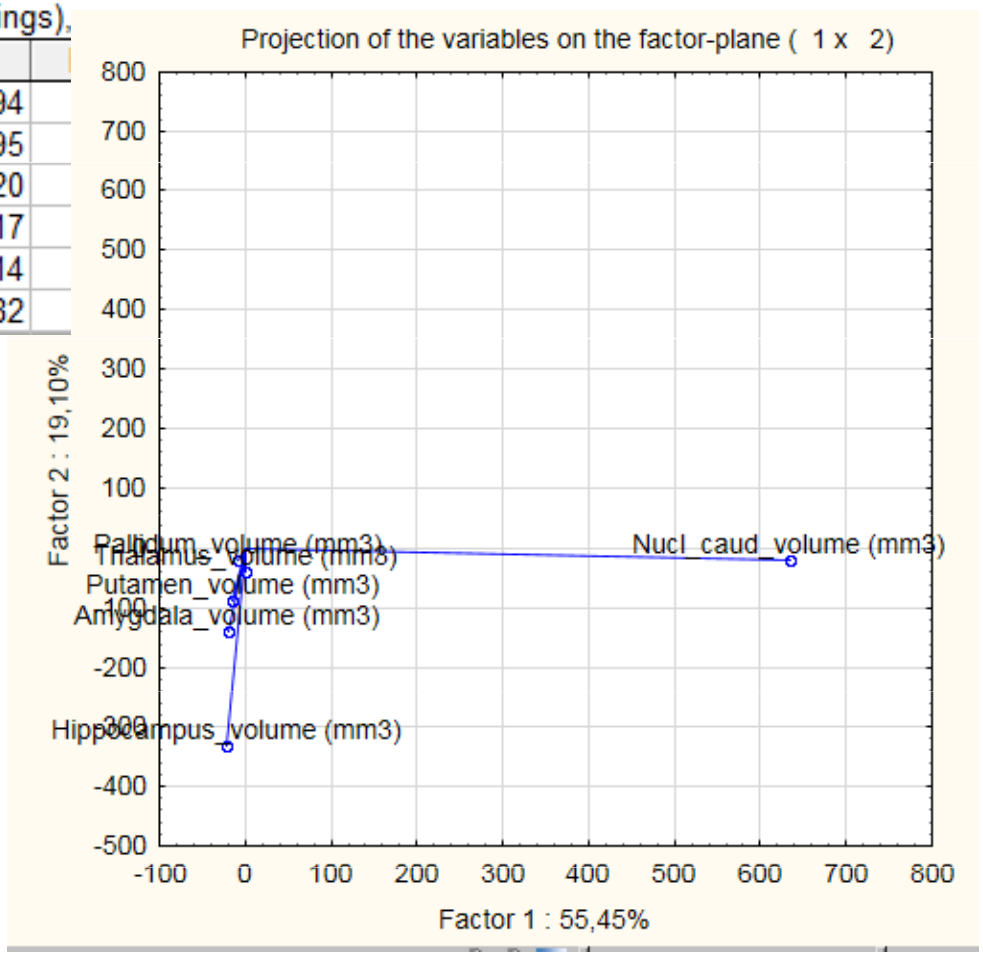

Z výsledků vyplývá, že:

- 1. hlavní komponenta je nejvíce korelovaná s objemem Nucleus caudatus
- 2. hlavní komponenta je korelovaná s objemem hipokampu a také s objemem amygdaly a putamenu

PCA – příklad – řešení v softwaru SPSS

- **Zadání:** Proveďte PCA na objemech 6 mozkových struktur u 833 subjektů.
- **Řešení:** SPSS: Analyze – Dimension Reduction – Factor...
  - záložka Extraction:
    - volba metody (ponechat Principal components)
    - volba Correlation matrix či Covariance matrix (pozor, Correlation matrix je defaultní! tzn. přepnout na Covariance matrix)
    - možnost zatrhnout vykreslení Scree plotu
    - volba, kolik hlavních komponent se vytvoří (přepnout na Fixed number... a zvolit 6, když mám 6 vstupních proměnných)
  - záložka Rotation – ponechám zatržené „None“
  - záložka Scores... – zatrhnout „Save as variable“ a případně i zatrhnout „Display factor score coefficient matrix“

PCA – příklad – řešení v softwaru SPSS

Vlastní čísla

Total Variance Explained

	Component	Initial Eigenvalues[a] Total	% of Variance	Cumulative %
Raw	1	403676,975	55,454	55,454
	2	139067,087	19,104	74,558
	3	70200,250	9,644	84,202
	4	41840,703	5,748	89,950
	5	40421,085	5,553	95,503
	6	32737,942	4,497	100,000

Sutinový graf

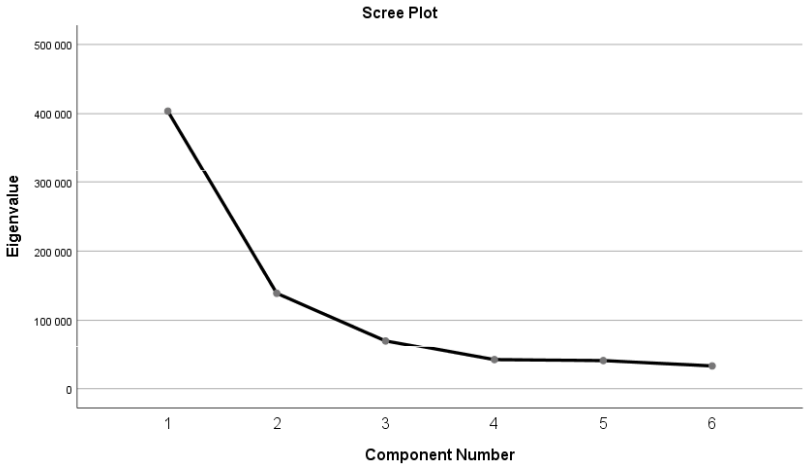

Matice vlastních vektorů *

Component Matrix[a]

	Raw Component 1	2	3	4	5	6
Hippocampus_volume (mm3)	-22,529	331,381	-12,852	-24,902	-62,176	-56,144
Amygdala_volume (mm3)	-19,876	139,756	-25,334	60,182	174,121	20,477
Thalamus_volume (mm3)	,658	37,303	261,504	20,916	4,384	12,703
Pallidum_volume (mm3)	-7,634	20,868	-27,707	184,595	-73,914	34,437
Putamen_volume (mm3)	-14,660	86,934	-15,376	-55,519	-27,413	166,766
Nucl_caud_volume (mm3)	634,429	18,367	-2,210	1,918	1,720	2,903

Extraction Method: Principal Component Analysis.

a. 6 components extracted.

Souřadnice subjektů v novém prostoru (jsou standardizované)

FAC1_1	FAC2_1	FAC3_1	FAC4_1	FAC5_1	FAC6_1
-,85256	,86362	,34174	,46067	-1,24179	-,15117
-,48179	1,36289	-1,59851	-,99769	-,20191	-,81984
,34317	1,27004	,72775	-,79788	-,40966	,70786
-,77548	1,43599	-1,01106	-,36313	-,27870	-1,94204
-,54519	,64565	-1,18128	-,52272	-,02490	,18146
-,19375	2,01086	-1,18890	-1,18152	,31479	-,25469

* normalizace vl. vektorů by se provedla v exelu (viz. slide 35)

Faktorová analýza (FA)

Faktorová analýza (FA)

- **Anglicky:** Factor Analysis
- **Princip:** Vytvoření nových proměnných (komponent, faktorů) z původních proměnných tak, aby zůstalo zachováno co nejvíce kovariance.

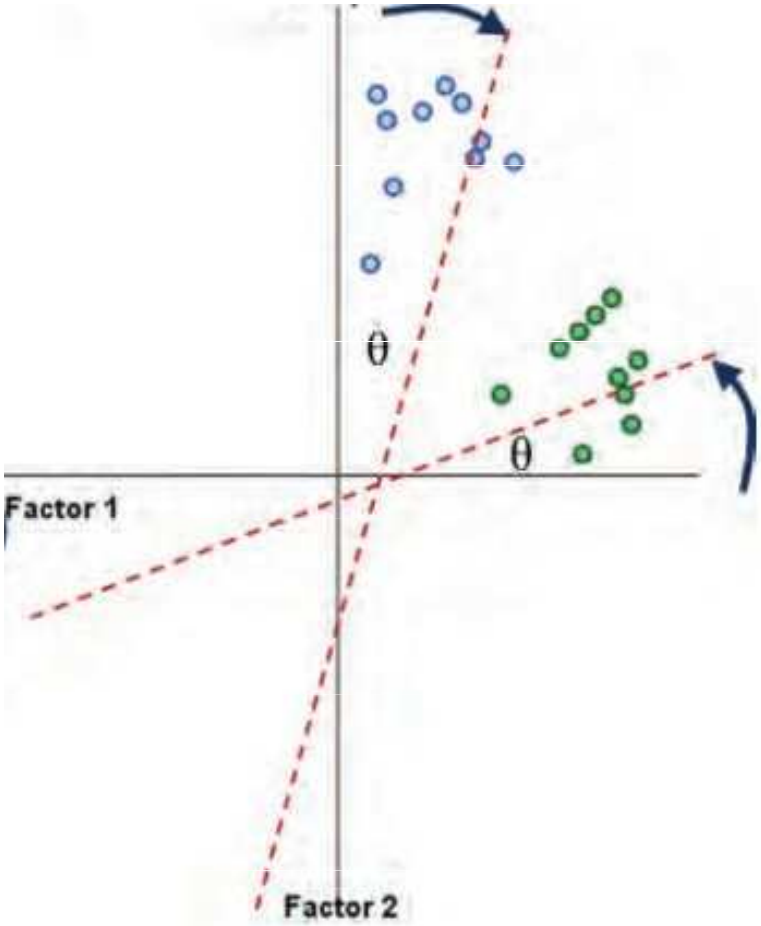

Stejný postup jako u PCA
+ 1 krok navíc – rotace komponent

Výhoda oproti PCA:
+ lepší interpretace nových proměnných

Nevýhoda oproti PCA:
- prostor pro subjektivní názor analytika při výběru rotace

Faktorová analýza

- faktorová analýza se snaží vysvětlit strukturu dat pomocí tzv. společných faktorů vysvětlujících sadu původních proměnných
- cíle, předpoklady, vstupní data a většina výpočtů obdobná jako u analýzy hlavních komponent
- čím se principielně liší od analýzy hlavních komponent?
  - Analýza hlavních komponent – vysvětlení maxima variability v datech
  - Faktorová analýza – vysvětlení maxima kovariance mezi popisnými proměnnými
- čím se prakticky liší od analýzy hlavních komponent?
  - Hlavním praktickým rozdílem je rotace proměnných tak, aby se vytvořené faktorové osy daly dobře interpretovat
  - Výhodou je lepší interpretace vztahu původních proměnných
  - Nevýhodou je prostor pro subjektivní názor analytika daný výběrem rotace
- typy faktorové analýzy
  - Vysvětlující (Explanatory) – snaží se identifikovat minimální počet faktorů pro vysvětlení dat
  - Potvrzující (Confirmatory) – testuje hypotézy ohledně skryté struktury v datech

Společné faktory a základní možné rotace

Společný faktor *Pozorovaná proměnná* *Unikátní faktor*

Rotace ortogonální

- Nezávislé faktory

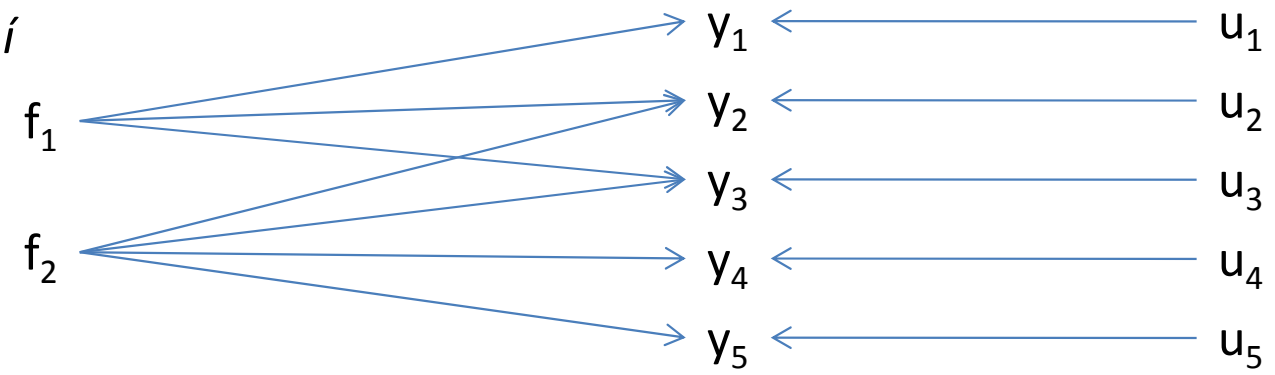

Rotace neortogonální

- Faktory jsou závislé za účelem zvýšení intepretovatelnosti

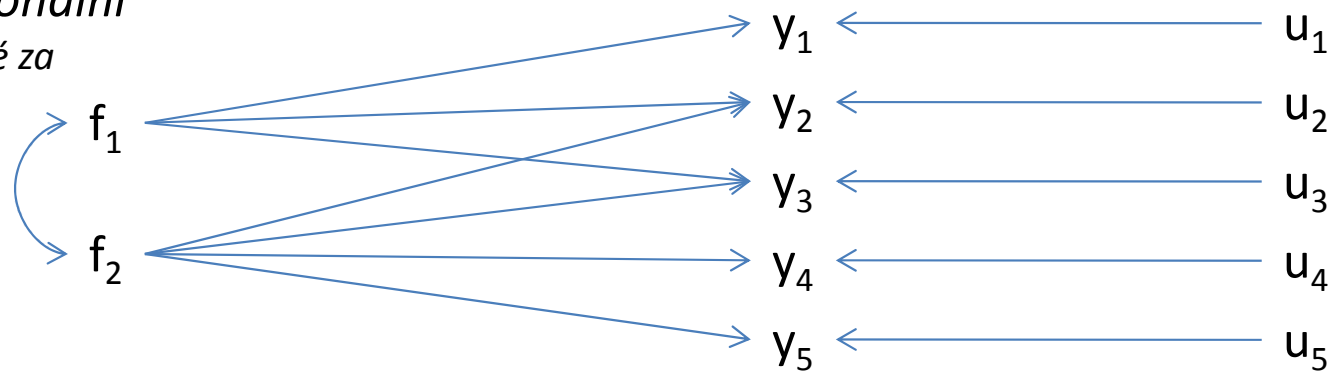

Faktorová analýza – postup výpočtu

1. extrakce prvotních faktorů z kovarianční matice (analogie vlastních vektorů v PCA)
   - oproti PCA pracuje pouze s částí variability každé proměnné (tzv. communality), která je sdílena společnými faktory
   - několik možných algoritmů – principal factoring, metoda nejmenších čtverců, maximum likelihood apod.
   - výsledkem je komplexní struktura faktorů (obdobná PCA), kde řada faktorů má významné loadings (vztahy) k původním proměnným, počet takových faktorů je tzv. komplexita faktorů
2. v druhém kroku je rotací dosaženo zjednodušení struktury faktorů, tj. vztah mezi společnými faktory a původními proměnnými je zjednodušen (každá původní proměnná má hlavní vztah s jedním faktorem nebo malým počtem faktorů)
   - dva hlavní typy rotace:
     - ortogonální – faktory nemohou být korelovány, jsou tedy zcela nezávislé
     - neortogonální – faktory mohou být korelovány, nejsou tedy zcela nezávislé; vzhledem ke korelacím obtížnější interpretace

Faktorová analýza - rotace

- Ortogonální rotace
  - Quartimax – minimalizuje sumu čtverců loadings původních proměnných na faktorových osách, tedy zjednodušuje řádky matice loadings (=každá původní proměnná má největší loadings na jedné faktorové ose)
  - Varimax – zjednodušuje sloupce matice loadings
  - Equimax – zjednodušuje řádky i sloupce matice loadings
  - Biquartimax – varianta equimax
- Neortogonální rotace
  - Oblimax
  - Quartimin
  - Oblimin
  - Covarimin
  - Biquartimin
  - Atd.

FA – příklad – řešení v softwaru R

- **Zadání:** Proveďte FA na datech z dotazníků.
- **Řešení:** Použití funkce „fa“ z knihovny „psych“.

  Detailní výpočet v souboru FA_ukazka.R

FA – příklad – řešení v softwaru SPSS

- **Zadání:** Proveďte FA na datech z dotazníků.
- **Řešení:** SPSS: Analyze – Dimension Reduction – Factor...
  - záložka Extraction:
    - volba metody – Unweighted least squares (to by mělo odpovídat fm=„minres“ v Rku)
    - možnost zatrhnout vykreslení Scree plotu
    - volba, kolik faktorů se vytvoří (přepnout na Fixed number... a zvolit nejprve 2, pokud je možné je interpretovat, změnit na 3 atd.)
  - záložka Rotation – několik možností, zvolit např. „Varimax“ (zkusit případně více rotací a podívat se, co dává nejvíce interpretovatelné výsledky)
  - záložka Scores... – zatrhnout „Save as variable“; lze zvolit více metod, např. Bartlett (hodnoty jsou však mírně odlišné od hodnot z Rka)
- **Výsledek:** Pro interpretaci faktorů použít „Rotated Factor Matrix“ (zkopírovat do excelu a podívat se, u kterých původních proměnných jsou pro jednotlivé faktory hodnoty větší než např. 0,7)

Poděkování

Příprava výukových materiálů předmětu
„DSAN02 Pokročilé metody analýzy dat v neurovědách“
byla finančně podporována prostředky projektu FRMU
č. MUNI/FR/0260/2014 „Pokročilé metody analýzy dat
v neurovědách jako nový předmět na LF MU“