

IV107 Bioinformatika I

Přednáška 11

Katedra informačních technologií
Masarykova Univerzita Brno

Jaro 2011

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Algoritmy v bioinformatice

- ▶ Vyhledávání v řetězcích
 - ▶ Boyer-Moore
 - ▶ pomocí konečného automatu
 - ▶ suffixové stromy
 - ▶ suffixové pole
- ▶ Tandemové opakování
- ▶ Palindromy
- ▶ DP - varianty algoritmu Needleman-Wunsch

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Statistické učení a klasifikace

Statistika více proměnných, ale na rozdíl např. od analýzy rozptylu a regresní analýzy pozorované proměnné nejsou spojité. Data patří do diskrétních tříd.

- ▶ Shlukování
- ▶ Diskriminační analýza
- ▶ Rozhodovací stromy
- ▶ Umělé neuronové sítě
- ▶ SVM

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště
Zkouška

Outline

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

Shlukování

Rozdělení dat do skupin podle společných vlastností, resp.
blízkosti v nějakém prostoru

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

- ▶ Hierarchické
 - ▶ zespodu
 - ▶ shora
- ▶ Nehierarchické (např. centroidní "k-means")

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Typy shlukování - podle vzdálenostní funkce

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

- ▶ L_p -normy ($D = (dx^p + dy^p)^{1/p}$)
 - ▶ Manhattan ($D = dx + dy$)
 - ▶ euklidovská ($D = \sqrt{dx^2 + dy^2}$)
- ▶ Čebyševova ($D = \max(dx, dy)$)
- ▶ vektorový součin ($D = X \cdot Y$)
- ▶ korelační koeficient
- ▶ editační
 - ▶ Levenshtein
 - ▶ Hamming

Data můžou být definovaná vlastnostmi (souřadnice)

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

A = (3,1,"white")

B = (4,1,"blue")

C = (3,2,"white")

D = (3,0,"red")

Data můžou být definovaná pomocí párové vzdálenosti

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

	A	B	C	D
A	0			
B	3	0		
C	2	4	0	
D	3	1	2	0

Vzdálenostní matice

Typy shlukování - podle určování vzdálenosti

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

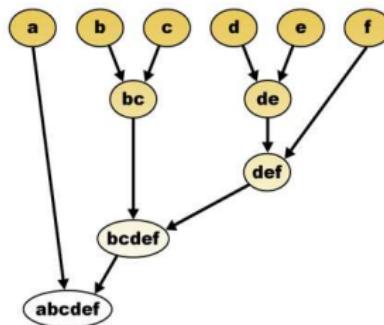
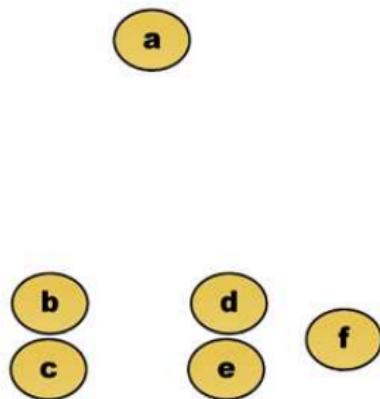
Bayesova teorie

Příště

Zkouška

- ▶ nejbližší soused
- ▶ nejvzdálenější soused
- ▶ centroidní
- ▶ párová (podobné centroidnímu, když centroid nelze spočítat)

Hierarchické agglomerativní shlukování



Shluková analýza

PCA - Principal component analysis

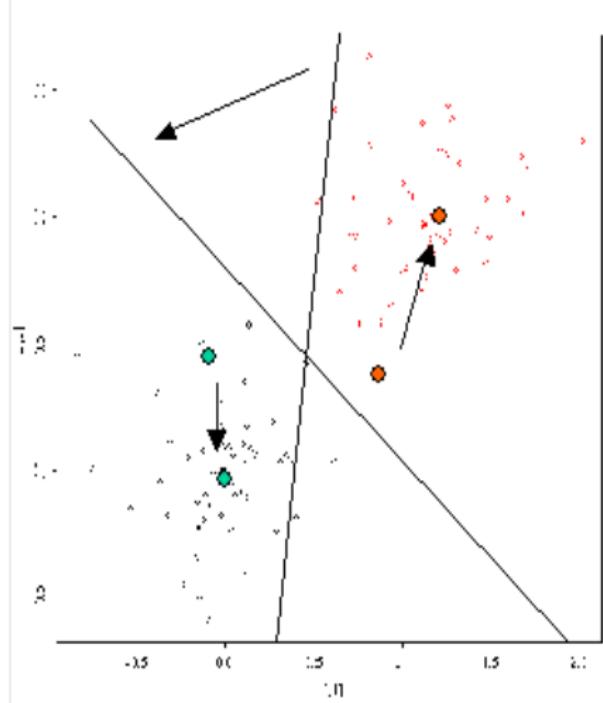
LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Nehierarchické centroidní shlukování



Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

- ▶ expresní profily genů
- ▶ sekvence genů/proteinů
- ▶ proteiny podle schopnosti interakce
- ▶ struktury proteinů (CATH)
- ▶ segmentace

Shluková analýza

PCA - Principal component analysis

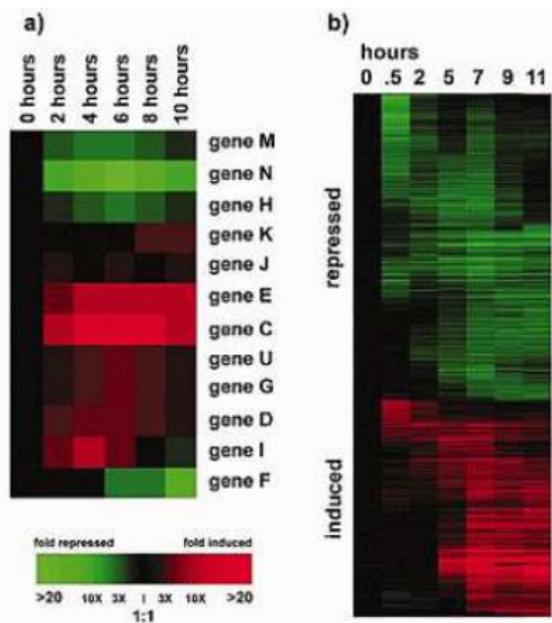
LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shlukování genů podle expresních profilů



Shluková analýza

PCA - Principal component analysis

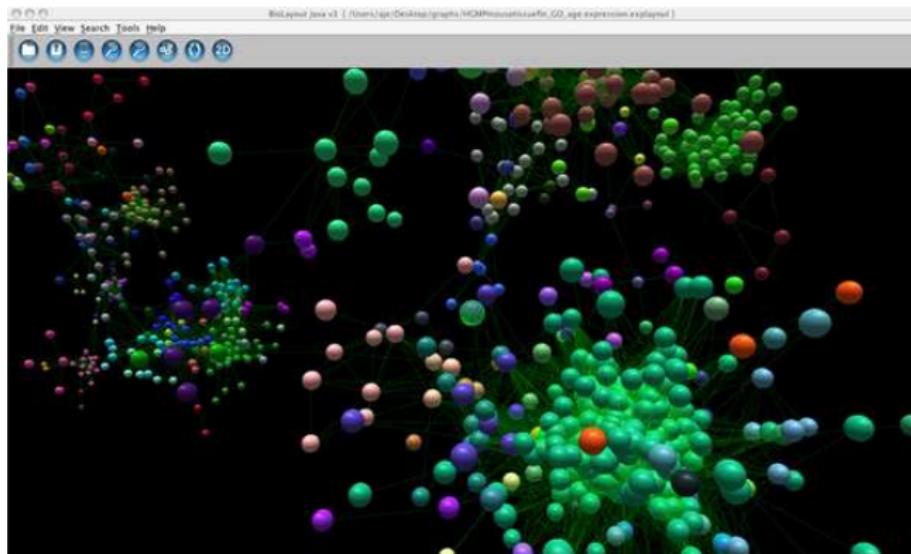
LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shlukování genů podle expresních profilů vede ke skupinám s podobnou funkcí.
Podobných výsledků lze dosáhnout použitím informací o interakcích mezi proteiny



Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Outline

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

PCA

Transformuje data do nového ortogonálního souřadnicového systému tak, že osi nejnižšího rádu pokrývají největší část variability dat.

[Shluková analýza](#)

[PCA - Principal component analysis](#)

[LDA - Linear Discriminant Analysis](#)

[Bayesova teorie](#)

[Příště](#)

[Zkouška](#)

Transformace souřadnicové soustavy v PCA

Shluková analýza

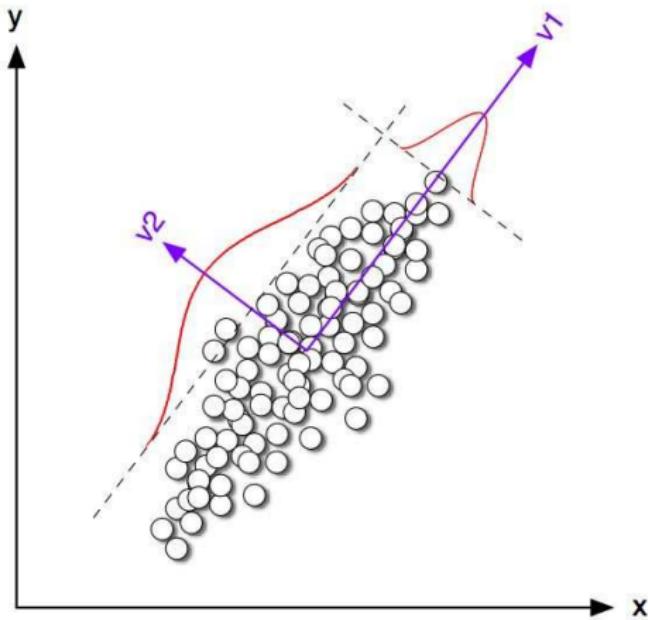
PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška



Outline

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

LDA

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

Naleze ne lineární transformaci jednotlivých parametrů, která poskytuje nejlepší separaci do tříd.

LDA najde lineární kombinaci vlastností, podle které lze nejlépe data klasifikovat

Shluková analýza

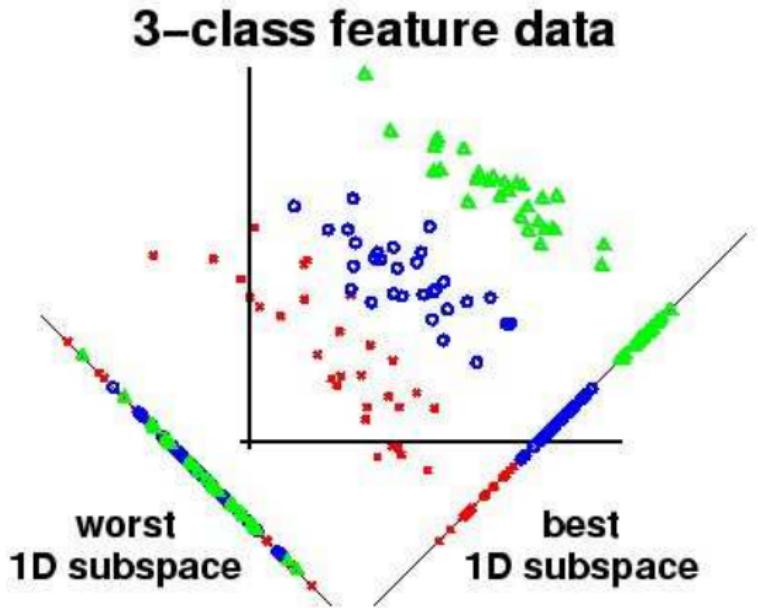
PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška



Outline

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

Bayesova veta

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Lze odvodit ze vztahu $P(X|Y) = \frac{P(X \cap Y)}{P(Y)}$

V případě aplikace v klasifikaci a statistickém učení budou A různé hypotézy o příslušnosti dat k určité třídě. B budou pozorované parametry.

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Příklad klasifikace s použitím Bayesovy teorie

Shluková analýza

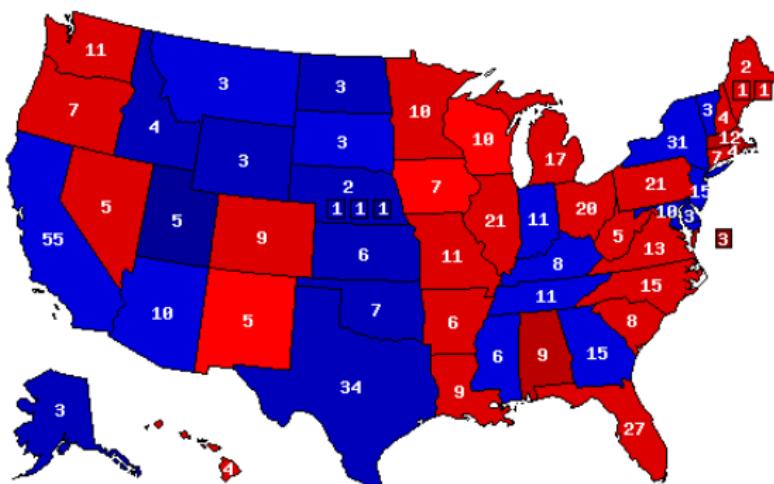
PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška



Hypotéza 1) bydlí na západě 2) bydlí na východě USA
Experiment: zavolám náhodně zvolenému američanovi a zeptám se koho volil, republikány (modře) nebo demokraty (červeně). Výsledek: podle odpovědi se změní pravděpodobnost pravdivosti jednotlivých hypotéz

Outline

Shluková analýza

PCA - Principal component analysis

LDA - Linear Discriminant Analysis

Bayesova teorie

Příště

Zkouška

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

Příště

Zkouška A107

30.5.2008 14:00

13.6.2008 16:00

20.6.2008 14:00

28.6.2008 10:00 opravny

Shluková analýza

PCA - Principal component
analysis

LDA - Linear Discriminant
Analysis

Bayesova teorie

Příště

Zkouška

Dodatek

For Further Reading

Dodatek

For Further Reading

Dodatek

For Further Reading

X