

# Vytěžování Dat

## Přednáška 4 – Shluková analýza


Miroslav Čepek

Fakulta Elektrotechnická, ČVUT

14.10.2011

# Co to je shluková analýza

- Je jednou ze základních úloh vytěžování dat.
- Jde o seskupení objektů do skupin podle jejich vlastností. Tak aby si objekty ve skupinách byly "nějak" podobné.
- A zároveň nebyly podobné objektů v jiných skupinách.



# Co to je shluková analýza (II)

- V principu jde o optimalizační problém.
- Co se musí optimalizovat?
  - Počet shluků (skupin)
  - Přiřazení instancí do shluků

# Co to je shluková analýza (II)

- V principu jde o optimalizační problém.
- Co se musí optimalizovat?
  - Počet shluků (skupin)
  - Přiřazení instancí do shluků

# Jak zjistit, že jsou si dva vzory podobné?

- To je obecně velmi složitá otázka.
- Protože shlukovou analýzu budou provádět hlavně počítače, musí být výsledkem nějaké číslo.
- Z matematické analýzy známe pojem metrika – což je jiné označení vzdálenosti.
- Metrika musí splňovat několik základních podmínek, aby ji bylo možné použít.
  - $d(x, y) \geq 0$
  - $d(x, y) = d(y, x)$
  - $d(x, y) = 0 \Leftrightarrow x = y$
  - $d(x, y) + d(y, z) \geq d(x, y)$

# Jak zjistit, že jsou si dva vzory podobné?

- To je obecně velmi složitá otázka.
- Protože shlukovou analýzu budou provádět hlavně počítače, musí být výsledkem nějaké číslo.
- Z matematické analýzy známe pojem metrika – což je jiné označení vzdálenosti.
- Metrika musí splňovat několik základních podmínek, aby ji bylo možné použít.
  - $d(x, y) \geq 0$
  - $d(x, y) = d(y, x)$
  - $d(x, y) = 0 \Leftrightarrow x = y$
  - $d(x, y) + d(y, z) \geq d(x, y)$

# Metriky

- Jaké znáte metriky?

- Eukleidovská metrika
- Manhattanská metrika
- Kosinová metrika
- Příklady dalších metrik
  - Editační vzdálenost (vzdálesnost dvou slov = počet změn, kterými můžu změnit jedno slovo na druhé)
  - Grafová metrika (počet hran, které musím v grafu projít, abych se dostal do z jednoho uzlu do druhého)
  - [http://en.wikipedia.org/wiki/Metric\\_space](http://en.wikipedia.org/wiki/Metric_space)

# Metriky

- Jaké znáte metriky?
- Eukleidovská metrika
- Manhattanská metrika
- Kosinová metrika
- Příklady dalších metrik
  - Editační vzdálenost (vzdálesnost dvou slov = počet změn, kterými můžu změnit jedno slovo na druhé)
  - Grafová metrika (počet hran, které musím v grafu projít, abych se dostal do z jednoho uzlu do druhého)
  - [http://en.wikipedia.org/wiki/Metric\\_space](http://en.wikipedia.org/wiki/Metric_space)

# Metriky

- Jaké znáte metriky?
- Eukleidovská metrika
- Manhattanská metrika
- Kosinová metrika
- Příklady dalších metrik
  - Editační vzdálenost (vzdálesnost dvou slov = počet změn, kterými můžu změnit jedno slovo na druhé)
  - Grafová metrika (počet hran, které musím v grafu projít, abych se dostal do z jednoho uzlu do druhého)
  - [http://en.wikipedia.org/wiki/Metric\\_space](http://en.wikipedia.org/wiki/Metric_space)

# Eukleidovská metrika

- Nejpřirozenější metrika, protože se s ní běžně setkáváme.
- Jak změříme vzdálenost dvou bodů na tabuli?
- Pravítkem :)
- A když známe souřadnice, můžeme ji spočítat. Jak?

# Eukleidovská metrika

- Nejpřirozenější metrika, protože se s ní běžně setkáváme.
- Jak změříme vzdálenost dvou bodů na tabuli?
- Pravítkem :)!
- A když známe souřadnice, můžeme ji spočítat. Jak?

# Eukleidovská metrika (II)

- Pythagorova věta!  $c = \sqrt{a^2 + b^2}$
- A Pythagorovu větu můžeme zobecnit pro  $\mathbb{R}^n$

$$\vec{x} = (x_1, x_2, \dots, x_n), \vec{y} = (y_1, y_2, \dots, y_n)$$

$$dist(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

# Eukleidovská metrika (II)

- Pythagorova věta!  $c = \sqrt{a^2 + b^2}$
- A Pythagorovu větu můžeme zobecnit pro  $\mathbb{R}^n$


$$\vec{x} = (x_1, x_2, \dots, x_n), \vec{y} = (y_1, y_2, \dots, y_n)$$

$$dist(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

# Manhattanská metrika (City-block distance)

- Základní myšlenka: Kolik bloků ve městě musím obejít, abych se dostal z jednoho místa na druhé?
- Nebo také – kolik tahů králem musím udělat abych se dostal z jednoho místa šachovnice na druhé?

# Manhattanská metrika (City-block distance) (II)



- Pokud znám souřadnice, vzdálenost spočítám takto:

$$dist(\vec{x}, \vec{y}) = |x_1 - y_1| + |x_2 - y_2| + \dots + |x_n - y_n|$$

# Kosinová vzdálenost

- Vzdálenost dvou vektorů je úhel, který svírají.


$$\text{similarity}(\vec{x}, \vec{y}) = \frac{\sum_{i=1}^n (x_i * y_i)}{\sqrt{\sum_{i=1}^n (x_i^2) * \sum_{i=1}^n (y_i^2)}}$$

- Výsledky této funkce jsou v rozmezí  $-1 \dots +1$ .  $-1$  znamená úplný opak,  $0$  nezávislost a  $+1$  naprostou shodu.
- Aby výsledky vyhovovali definici metriky je potřeba podobnost odečítst od jedné.

$$\text{dist}(\vec{x}, \vec{y}) = 1 - \text{similarity}(\vec{x}, \vec{y})$$

# Shlukování pomocí KMeans

- Jednostlivé shluky budou zastoupeny jedním reprezentantem, který ponese vlastnosti typické pro danou skupinu/shluk.
- Každá instance (vzor) v datech bude reprezentována reprezentantem, který je jí nejpodobnější .
- Jinými slovy – který ji bude nejblíž (v dané metrice).



# Shlukování pomocí KMeans

- Jak určit, kde je správné místo pro reprezentanty?
- Chceme, aby vzdálenost mezi reprezentanty a instancemi byla co nejmenší.
- Snažíme se vlastně minimalizovat součet všech vzdáleností mezi instancemi a jejich reprezentanty  $\Rightarrow$  jde o optimalizační problém.
- Taková optimalizace se dá řešit mnoha způsoby, ale jeden z nejjednodušších je iterační.

# Algoritmus KMeans – značení

- Máme množinu  $n$  vstupních vzorů/instancí (vektorů)  $x_k$ . Jednotlivé složky vektoru budeme označovat  $x_k(s)$ .
- A máme množinu  $K$  reprezentantů.  $means_i^t$  je  $i$ -tý reprezentant v kroku  $t$ .


# Algoritmus KMeans

- ① Nastav reprezentanty  $means_i^0$  do náhodných počátečních bodů.
- ② Najdi a přiřaď každé instanci jeho nejbližšího reprezentanta.
  - $\forall x$  najdi  $j$  tak, aby  $dist(x, means_j^t) \leq dist(x, means_i^t) \forall i$
  - a pro každého reprezentanta  $means_i^t$  vytvoř množinu  $nearest_i^t$  instancí, ke kterým je nejblíž.
- ③ Přesuň reprezentanta tak aby ležel "uprostřed" své množiny nejbližších instancí.
  - $means_i^{t+1}(s) = \frac{1}{\|nearest_i^t\|} \sum_{x_k \in nearest_i^t} x_k(s)$
- ④ Pokud se změnila poloha alespoň jednoho prezentanta, vrať se na bod 2. Jinak skonči.


# Ilustrace KMeans



# Illustrace KMeans (II)




# Illustrace KMeans (III)



# Illustrace KMeans (IV)



# Illustrace KMeans (V)



# Pohádka o Algoritmu KMeans :)

- Once there was a land with N houses.
- One day K kings arrived to this land.
- Each house was taken by the nearest king.
- But the community wanted their king to be at the center of the village, so the throne was moved there
- Then the kings realized that some houses were closer to them now, so they took those houses, but they lost some. This went on and on... (2-3-4)
- Until one day they couldn't move anymore, so they settled down and lived happily ever after in their village...

# Problémy a stabilita shlukování pomocí KMeans

- Dopadne shlukování pomocí KMeans pokaždé stejně?
- Jak určit správný počet středů (shluků)?
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K?

# Problémy a stabilita shlukování pomocí KMeans

- Dopadne shlukování pomocí KMeans pokaždé stejně?
- Jak určit správný počet středů (shluků)?
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K?

# Problémy a stabilita shlukování pomocí KMeans

- Dopadne shlukování pomocí KMeans pokaždé stejně?
- Jak určit správný počet středů (shluků)?
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K?

# Vyhodnocení shluků vytvořených KMeans algoritmem

- Jednou z možných metod je tzv. silueta.
- Silueta pro každou vstupní instanci spočítá jistotu zařazení instance do daného shluku.

$$s(x_k) = \frac{b(x_k) - a(x_k)}{\max(a(x_k), b(x_k))}$$





- $a(x_k)$  je průměrná vzdálenost  $x_k$  od ostatních instancí shluku, ke kterému je přiřazena.
- $b(x_k)$  je průměrná vzdálenost  $x_k$  od instancí v nejbližším dalším shluku.
- Výsledné hodnoty jsou mezi -1 ( $x_k$  do shluku úplně nepatří) a +1 (úplně patří)
- ftp:

//ftp.win.ua.ac.be/pub/preprints/87/Silgra87.pdf

# Vyhodnocení shluků vytvořených KMeans algoritmem (II)

- Pokud vypočítáte siletu pro všechny instance a vykreslíte ji do grafu, můžete si udělat představu, jak shlukování dopadlo.

# Ukázka Siluety – shluky Kosatců



- Které shlukování dopadlo lépe?
- Co třeba průměrná silueta přes všechny instance (ideálně přes testovací data)?

# Stabilita shluků

- Jak zkusit, že shluky opravdu v datech jsou a výsledné shluky nejsou náhoda?
- Náhodným smazáním např. 10% různých instancí vygenerovat M podmnožin dat a spustit shlukování na každé podmnožině.
- Existuje několik ukázkových apletů/aplikací, kde si můžete zkusit, jak algoritmus funguje.
- [http://home.dei.polimi.it/matteucc/Clustering/tutorial\\_html/AppletKM.html](http://home.dei.polimi.it/matteucc/Clustering/tutorial_html/AppletKM.html)

# Hierarchické shlukování – úvod

- KMeans, jak jsme viděli, má některé mouchy.
  - Kolik je v datech shluků?
  - Závislost výsledků na počátečních podmírkách.
- Šlo by shlukování dělat i jinak?
  - Šlo :). Jednou z možností je Hierarchické shlukování.
  - Základní myslenka je, že vytvoříme hierarchii shluků. Vždy spojíme dva nejpodobnější shluky do jednoho většího.
  - A takto budeme pokračovat, dokud nevytvoříme jeden mega-shluk.

# Hierarchické shlukování – úvod

- KMeans, jak jsme viděli, má některé mouchy.
  - Kolik je v datech shluků?
  - Závislost výsledků na počátečních podmírkách.
- Šlo by shlukování dělat i jinak?
- Šlo :). Jednou z možností je Hierarchické shlukování.
- Základní myšlenka je, že vytvoříme hierarchii shluků. Vždy spojíme dva nejpodobnější shluky do jednoho většího.
- A takto budeme pokračovat, dokud nevytvoříme jeden mega-shluk.


# Hierarchické shlukování

- ① Začne ze stavu, kdy každá instance je jedním shlukem.
- ② Najdi dva nejbližší shluky.
- ③ Spoj je do jednoho.
- ④ Zůstávají nějaké shluky, které lze spojit? Pokud ano, vrať se na bod 2.


# Nejbližší shluky

- Jak zjistím vzdálenost dvou shluků?
- Dokud shluky obsahují jen jednu instanci, je spočítání vzdálenosti jednoduché. Ale pak?
- Vzdálenost shluků je určena
  - Nejbližší sousedé – vzdáleností nejbližších instancí ve shluku.
  - Nejvzdálenější sousedé – vzdáleností nejvzdálenějších instancí ve shluku.
  - Vzdálenost středů – vzdáleností center (středů) shluků.
  - Průměrná vzdálenost – průměrná vzdálenost mezi všemi instancemi v obojích shlucích


# Vzdálenost shluků – ilustrace




Nejkratší vzdálenost



Průměrná vzdálenost




Největší vzdálenost



Vzdálenost mezi reprezentanty

# Dendrogram

- Když zkusíme vizualizovat postup shlukování – tj. které shluky se spojují, získáme strom – dendrogram.
- Jak nalezneme počet shluků? Výběrem :), podle toho, kolik shluků potřebujeme nebo kolik vyjde jako nejvhodnější.



# Vyhodnocení hierarchického shlukování

- Můžeme opět použít siluetu, stejně jak jsme ji používali v K-Means.
- Druhou možností je vypočítat CPCC (Cophenetic Correlation Coeffitient).
- CPCC je normovaná kovariance vzdáleností v původním prostoru a v dendrogramu.
- Pokud je hodnota CPCC menší než cca 0.8, všechny instance patří do jediného velkého shluku.
- Obecně platí, že čím vyšší je kofenetický koeficient korelace, tím nižší je ztráta informací, vznikající v procesu slučování objektů do shluků.

# Další informace a zdroje

- [http://cmp.felk.cvut.cz/cmp/courses/recognition/zapis\\_prednasky/zapis\\_02/13/shlukovani.pdf](http://cmp.felk.cvut.cz/cmp/courses/recognition/zapis_prednasky/zapis_02/13/shlukovani.pdf)
- <http://www.fit.vutbr.cz/study/courses/ZZD/public/seminar0304/hlukovani2.pdf>