

Vytěžování Dat

Přednáška 4 – Shluková analýza

Miroslav Čepek

Katedra počítačů, Computational Intelligence Group




Evropský sociální fond Praha & EU:
Investujeme do vaší budoucnosti

14.10.2014

Co to je shluková analýza

- Je jednou ze základních úloh vytěžování dat.
- Jde o *třídění objektů do skupin* podle jejich vlastností.
 - ▶ Tak aby si objekty ve skupinách byly "nějak" podobné.
 - ▶ A zároveň nebyly podobné objektům 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.
- Shlukovou analýzu provádí hlavně počítače, obvyklé je zavedení číselné vzdálenostní funkce:
 - ▶ $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$,
 - ▶ kde \mathcal{X} je prostor instancí,
 - ▶ vzdálenost je nepřímo úměrná podobnosti.
- Při splnění několika podmínek mluvíme o (vzdálenostní) *metrice*:
 - ▶ $d(x, y) \geq 0$
 - ▶ $d(x, y) = d(y, x)$
 - ▶ $d(x, y) = 0 \Leftrightarrow x = y$
 - ▶ $d(x, y) + d(y, z) \geq d(x, z)$

Jak zjistit, že jsou si dva vzory podobné?

- To je obecně velmi složitá otázka.
- Shlukovou analýzu provádí hlavně počítače, obvyklé je zavedení číselné vzdálenostní funkce:
 - ▶ $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$,
 - ▶ kde \mathcal{X} je prostor instancí,
 - ▶ vzdálenost je nepřímo úměrná podobnosti.
- Při splnění několika podmínek mluvíme o (vzdálenostní) *metrice*:
 - ▶ $d(x, y) \geq 0$
 - ▶ $d(x, y) = d(y, x)$
 - ▶ $d(x, y) = 0 \Leftrightarrow x = y$
 - ▶ $d(x, y) + d(y, z) \geq d(x, z)$

Metriky

- Jaké znáte metriky?

- ▶ Eukleidovská metrika
- ▶ Manhattanská metrika
- ▶ Kosinová metrika

- Příklady dalších metrik

- ▶ Editační vzdálenost (vzdálenost dvou slov = počet změn, kterými můžu změnit jedno slovo na druhé)
- ▶ Grafová metrika (počet hran, které musím v grafu projít, abych se dostal z jednoho uzlu do druhého)
- ▶ http://en.wikipedia.org/wiki/Metric_space

Metriky

- Jaké znáte metriky?

- ▶ Eukleidovská metrika
- ▶ Manhattanská metrika
- ▶ Kosinová metrika

- Příklady dalších metrik

- ▶ Editační vzdálenost (vzdálenost dvou slov = počet změn, kterými můžu změnit jedno slovo na druhé)
- ▶ Grafová metrika (počet hran, které musím v grafu projít, abych se dostal z jednoho uzlu do druhého)
- ▶ http://en.wikipedia.org/wiki/Metric_space

Metriky

- Jaké znáte metriky?
 - ▶ Eukleidovská metrika
 - ▶ Manhattanská metrika
 - ▶ Kosinová metrika
- Příklady dalších metrik
 - ▶ Editační vzdálenost (vzdálenost dvou slov = počet změn, kterými můžu změnit jedno slovo na druhé)
 - ▶ Grafová metrika (počet hran, které musím v grafu projít, abych se dostal z jednoho uzlu do druhého)
 - ▶ 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

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

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

Eukleidovská metrika (II)

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


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

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

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 spočítam takto:

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

Kosinová vzdálenost

- Vzdálenost dvou vektorů délky n odpovídá úhlu, který svírají:


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

- Oborem hodnot této funkce je interval $\langle -1, +1 \rangle$.
- -1 znamená úplný opak, 0 nezávislost a $+1$ naprostou shodu.
- Převod na vzdálenost:

$$d(\mathbf{x}, \mathbf{y}) = 1 - \text{similarity}(\mathbf{x}, \mathbf{y})$$

Shlukování pomocí KMeans

- Jednotlivé shluky budou zastoupeny jedním reprezentantem.
 - ▶ Ten ponese vlastnosti typické pro danou skupinu/shluk.
- I každá instance (vzor) bude zastoupena jedním reprezentantem.
 - ▶ Tím, který je jí nejpodobnější.
 - ▶ Jinými slovy tím, který jí bude nejblíž (v dané metrice).



Algoritmus KMeans – značení

- Máme množinu N vstupních vzorů/instancí (vektorů) \mathbf{x}_i , $i \in 1 \dots N$. Jednotlivé složky vektoru budeme označovat $x_i(s)$, $s \in 1 \dots n$.
- A máme množinu K reprezentantů, vektorů \mathbf{c}_k^t . Kde $k \in 1 \dots K$ je index reprezentanta, t je číslo iteračního kroku, $c_k^t(s)$ je jednou z jeho složek.

Shlukování pomocí KMeans

- Jak určit, kde je správné místo pro reprezentanty shluků?
 - ▶ Vzdálenost mezi instancemi a jejich reprezentanty musí být co nejmenší.
 - ▶ Lze formulovat jako optimalizační problém:

$$\arg \min_{c_1 \dots c_K} \sum_{i=1}^N \min_k d^2(x_i, c_k)$$

- ▶ Jako d volíme euklidovskou vzdálenost.
- ▶ Jeden z nejjednodušších postupů je iterační.


Algoritmus KMeans

- ① Nastav reprezentanty c_k^0 do náhodných počátečních bodů.
- ② Najdi a přiřaď každé instanci jejího nejbližšího reprezentanta.
 - ▶ $\forall x_i$ najdi k tak, aby $\forall j d(x_i, c_k^t) \leq d(x_i, c_j^t)$,
 - ▶ pro každé c_k^t vytvoř množinu $nearest_k^t$ instancí, ke kterým je nejbližší.
- ③ Přesuň reprezentanta tak, aby ležel "uprostřed" své množiny nejbližších instancí.
 - ▶ $c_k^{t+1}(s) = \frac{1}{\|nearest_k^t\|} \sum_{x_i \in nearest_k^t} x_i(s)$
- ④ Pokud se změnila poloha alespoň jednoho středu, vrat' se na bod 2. Jinak skonči.


Illustrate KMeans



Illustrate KMeans (II)




Ilustrace KMeans (III)



Illustrate KMeans (IV)



Illustrate 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...

KMeans jako varianta EM algoritmu

- Lze najít analogii mezi KMeans a dřívější látkou kurzu?
- Ano, řada společných znaků s EM algoritmem:
 - ▶ Skrytá proměnná = přiřazení instancí ke shlukům.
 - ▶ E-krok = pro dané středy shluků určí rozdelení instancí do shluků.
 - ▶ M-krok = pro dané rozdelení instancí odhadní nové středy shluků.
- Odlišnosti od EM:
 - ▶ Nepracuje s věrohodností (lze ale ukázat, že minimalizace vzdálenosti ke středům je analogií).
 - ▶ Uvažuje ostré (hard) přiřazení ke shlukům, nikoli pravděpodobnostní.
- Závěr: KMeans lze považovat za příklad hard EM algoritmu.
- Existuje i klasická aplikace EM pro shlukování, model je směsí gaussovských rozdělení.

KMeans jako varianta EM algoritmu

- Lze najít analogii mezi KMeans a dřívější látkou kurzu?
- Ano, řada společných znaků s EM algoritmem:
 - ▶ Skrytá proměnná = přiřazení instancí ke shlukům.
 - ▶ E-krok = pro dané středy shluků určí rozdelení instancí do shluků.
 - ▶ M-krok = pro dané rozdelení instancí odhadní nové středy shluků.
- Odlišnosti od EM:
 - ▶ Nepracuje s věrohodností (lze ale ukázat, že minimalizace vzdálenosti ke středům je analogií).
 - ▶ Uvažuje ostré (hard) přiřazení ke shlukům, nikoli pravděpodobnostní.
- Závěr: KMeans lze považovat za příklad hard EM algoritmu.
- Existuje i klasická aplikace EM pro shlukování, model je směsí gaussovských rozdělení.

Vlastnosti KMeans algoritmu

- Může se KMeans zacyklit? NE
- Dopadne shlukování pomocí KMeans pokaždé stejně? NE
- Jak určit správný počet středů (shluků)? heuristicky
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K? viz dále

Vlastnosti KMeans algoritmu

- Může se KMeans zacyklit? NE
- Dopadne shlukování pomocí KMeans pokaždé stejně? NE
- Jak určit správný počet středů (shluků)? heuristicky
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K? viz dále

Vlastnosti KMeans algoritmu

- Může se KMeans zacyklit? NE
- Dopadne shlukování pomocí KMeans pokaždé stejně? NE
- Jak určit správný počet středů (shluků)? heuristicky
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K? viz dále

Vlastnosti KMeans algoritmu

- Může se KMeans zacyklit? NE
- Dopadne shlukování pomocí KMeans pokaždé stejně? NE
- Jak určit správný počet středů (shluků)? heuristicky
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K? viz dále

Vlastnosti KMeans algoritmu

- Může se KMeans zacyklit? NE
- Dopadne shlukování pomocí KMeans pokaždé stejně? NE
- Jak určit správný počet středů (shluků)? heuristicky
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K? viz dále

Vlastnosti KMeans algoritmu

- Může se KMeans zacyklit? NE
- Dopadne shlukování pomocí KMeans pokaždé stejně? NE
- Jak určit správný počet středů (shluků)? heuristicky
- Jak vyhodnotit jestli shlukování dopadlo dobře a jestli jsme zvolili přiměřené K? viz dále

Vyhodnocení rozkladu z KMeans algoritmu

- 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 rozkladu z KMeans algoritmu (II)

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

Ukázka Siluety – shluky Kosatců



Vyhodnocení rozkladu z KMeans algoritmu (III)

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

Vyhodnocení rozkladu z KMeans algoritmu (III)

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

Stabilita shluků

- Jak ověřit, že shluky nejsou nahodilé a odpovídají přirozeným třídám?
- 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

Interpretace shluků

- Mám shluky, co s nimi dál?

- ▶ Jaké skupiny objektů jednotlivé shluky reprezentují?
- ▶ Jaké jsou jejich typické vlastnosti? Můžeme je stručně anotovat?
- ▶ Co říkají pozice centroidů?
- ▶ Generalizují shluky vzhledem k dalším příznakům nepoužitým pro shlukování?

Interpretace shluků

- Mám shluky, co s nimi dál?
 - ▶ Jaké skupiny objektů jednotlivé shluky reprezentují?
 - ▶ Jaké jsou jejich typické vlastnosti? Můžeme je stručně anotovat?
 - ▶ Co říkají pozice centroidů?
 - ▶ Generalizují shluky vzhledem k dalším příznakům nepoužitým pro shlukování?

Hierarchické shlukování – úvod

- KMeans, jak jsme viděli, má některé mouchy.
 - ▶ Kolik je v datech shluků?
 - ▶ Závislost výsledků na počátečních podmínkách.
 - ▶ Upřednostňuje kulovitý tvar shluků.
- Šlo by shlukování dělat i jinak?
- Šlo :). Jednou z možností je *Hierarchické shlukování*.
 - ▶ Základní myslenka je, že vytvoříme hierarchii shluků.
 - ▶ Lze postupovat zdola nahoru nebo shora dolů.
 - ▶ V prvním případě vždy spojíme dva nejpodobnější shluky do jednoho většího.
 - ▶ Pokračujeme dokud nevytvoříme jediný shluk se všemi objekty.

Hierarchické shlukování – úvod

- KMeans, jak jsme viděli, má některé mouchy.
 - ▶ Kolik je v datech shluků?
 - ▶ Závislost výsledků na počátečních podmínkách.
 - ▶ Upřednostňuje kulovitý tvar shluků.
- Šlo by shlukování dělat i jinak?
- Šlo :). Jednou z možností je *Hierarchické shlukování*.
 - ▶ Základní myslenka je, že vytvoříme hierarchii shluků.
 - ▶ Lze postupovat zdola nahoru nebo shora dolů.
 - ▶ V prvním případě vždy spojíme dva nejpodobnější shluky do jednoho většího.
 - ▶ Pokračujeme dokud nevytvoříme jediný shluk se všemi objekty.


Agglomerativní 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, vrat' se na bod 2.


Nejbližší shluky

- Jak zjistím vzdálenost dvou shluků?
- Dokud shluky obsahují jen jednu instanci, je spočítání vzdálenosti jednoduché. Ale pak?
 - ▶ $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$ zobecníme na $\delta : 2^{\mathcal{X}} \times 2^{\mathcal{X}} \rightarrow \mathbb{R}$
- 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 obojíchlucích


Vzdálenost shluků – ilustrace




Nejkratší vzdálenost



Průměrná vzdálenost




Největší vzdálenost



Vzdálenost mezi reprezentanty

Dendrogram

- Vizualizací postupu shlukování získáme strom – dendrogram.
- Jak nalezneme konkrétní rozklad do shluků?
 - ▶ Řezem dendrogramu na dané výšce.
 - ▶ Jak volíme počet shluků? Lze přihlédnout k výšce větví.



Vyhodnocení hierarchického shlukování

- Můžeme opět použít siluetu, stejně jako u KMeans.
- Jinou možností je CPCC (Cophenetic Correlation Coefficient).
 - ▶ 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
- Jain et al.: **Data Clustering: A Review.** ACM Computing Surveys.