

МЕЖДУНАРОДНЫЙ СОЛОМОНОВ УНИВЕРСИТЕТ



Дмитрий Владимирович ЛАНДЭ

Лекция 7

“Кластерный анализ и информационный поиск”



Понятие «кластерного анализа»

Кластерный анализ - метод группировки экспериментальных данных в классы. Наблюдения, попавшие в один класс, в некотором смысле ближе друг к другу, чем к наблюдениям из других классов.

(Глоссарий.ru)

Пример кластеров сайтов - «групп подобия по контенту»
(www touchgraph.com)

Понятие информационного портрета

Портрет - модель реального объекта, выраженную его наиболее узнаваемыми чертами.

Информационный портрет документа - статистически значимая совокупность информационных характеристик.

В качестве информационного портрета темы можно рассматривать множество ключевых слов, наиболее точно (по статистическим и смысловым алгоритмам) отражающее информацию, соответствующую данной теме.

Тематической рубрике соответствует ее информационный портрет:

$$P_i = \{ v_{ij} \}, (j=1,..,K),$$

где v_{ij} –весовой коэффициент, соответствующий j -му терм, K - количество термов в словаре системы.

Взвешивание потока документов в пространстве информационного портрета

$M = \{m_{ij}\}$ ($i = 1,..,N; j = 1,..,K$) - матрица соответствия потока документов D информационному портрету l .

$D = \{d_i\}$ $\{i=1,K\}$. d_i – определяется как TF*IDF.

Близость D и P_i – $sim(D, P_i)$ – скалярное произведение K -мерных векторов.

Алгоритм взвешивания:

Латентное семантическое индексирование

Метод кластерного анализа **LSI** (латентного семантического индексирования), базируется на сингулярном разложении матриц (**SVD**). Сингулярным разложением матрицы A называется ее разложение вида $A=USV^T$, где U и V – ортогональные матрицы, а S – диагональная матрица, элементы которой $s_{ij} = 0$, если i не равно j , а $s_{ii} >= 0$. В рассматриваемом примере (таблиц взаимосвязей) матрица $A = M^T M$ – квадратная, однако метод LSI применяется и к прямоугольным матрицам, но в этих случаях размерность матрицы S соответствует рангу матрицы A .

В соответствии с методом LSI в рассмотрение берутся k наибольших сингулярных значений, а каждому такому сингулярному значению матрицы A соответствует кластер взаимосвязанных документов. A аппроксимируется матрицей $A_k = \sum u_i s_{ii} v_i^T$.

Метод LSI применим и к ранжированию выдачи информационно-поисковых систем, основанному на цитировании. Это алгоритм HITS (Hyperlink Induced Topic Search) – один из двух самых популярных на сегодня в области информационного поиска.

Ввиду своей вычислительной трудоемкости (равной $O(N^2)$, N – размерность A), этот метод LSI применяется только для относительно небольших матриц.

Взаимосвязь тем и метод k-means

Суть алгоритма k-means: случайным образом выбирается k векторов-строк, которые определяются как центроиды кластеров. Затем k кластеров наполняются – для каждого из оставшихся векторов-строк определяется близость к центроиду соответствующего кластера. После этого вектор-строка приписывается к тому кластеру, к которому он наиболее близок. После этого строки-векторы перегруппируются. Затем для каждого из новых кластеров заново определяется центроид. После этого заново выполняется процесс наполнения кластеров и т. д., пока процесс не стабилизируется или не зациклится.

Группировка тем методом k-means

В отличие от метода LSI, *k*-means идеально подходит для кластеризации динамических информационных потоков.

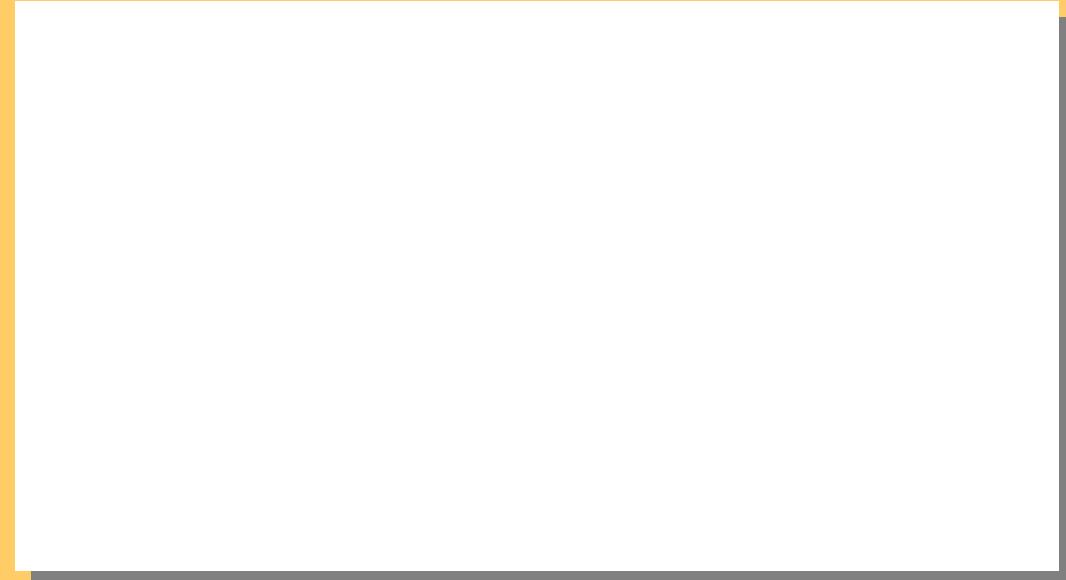
Укрупнение рубрик – актуальная задача кластерного анализа и она может быть решена путем их группировки по признакам подобия.

Выделение групп взаимосвязанных рубрик методом кластерного анализа *k*-means:

Метод, основанный на применении сетевого подхода - выявление сюжетов



Построение адаптивных интерфейсов уточнения запросов



Спасибо за внимание!

Ландэ Д.В
dwl@visti.net
http://poiskbook.kiev.ua

МЕЖДУНАРОДНЫЙ СОЛОМОНОВ
УНИВЕРСИТЕТ
Киев, Украина

