МЕЖДУНАРОДНЫЙ СОЛОМОНОВ УНИВЕРСИТЕТ

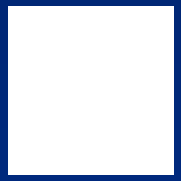

Дмитрий Владимирович ЛАНДЭ

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.

$D=\{d_i\}$ $\{i=1,K\}$. di – 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 $A_k = \Sigma u_i s_{ii} v_i^T$.
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 метод 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