

Юрий Лифшиц

ПОМИ РАН - СПбГУ ИТМО

Осень 2006

В ноябре 1997 при запросе собственного названия только одна из четырех ведущих поисковых систем выдавала себя в первой десятке.

Брин и Пейдж, “Анатомия поисковых систем”, 1998

Sergey Brin, Larry Page, Jon Kleinberg:



План лекции

1 Модели информационного поиска

- Булевская модель
- Векторная модель
- Вероятностная модель

2 Архитектура поисковой системы

3 PageRank

Часть I

Формально, что такое документ?

Формально, что такое запрос?

При каком условии мы считаем, что документ соответствует запросу?

Булевская модель

Словарь: $T = \{t_1, \dots, t_n\}$

Документ: $D \subset T$, иначе говоря $D \in \{0, 1\}^n$

Запрос: $t_5 \text{ OR } t_7 \text{ NOT } t_{12}$

Соответствие:

Формула запроса должна быть выполнена на документе.

Недостатки модели?

Снова коллекция документов, каждый из которых теперь является **мультимножеством** слов.

Определим матрицу M по формуле $M_{ij} = TF_{ij} \cdot IDF_i$, где:

- Частота терма TF_{ij} — относительная доля слова i в тексте j
- Обратная встречаемость в документах IDF_i — величина, обратная количеству документов, содержащих слово i

Физический смысл M_{ij} — степень соответствия слова i тексту j

Запрос: $t_3 \text{ AND } t_5$ (разрешаем только AND)

Релевантность в векторной модели

Запишем запрос в виде вектора:

$Q = "t_3 \text{ AND } t_5" = \{0, 0, 1, 0, 1, 0, \dots, 0\}$

Мерой релевантности будет **косинус** между запросом и документом:

$$R(Q, D) = \frac{Q \cdot D}{|D||Q|}$$

Вероятностная модель для чайников

Документ: множество слов (булевский вектор) $D = \{d_1, \dots, d_n\}$
Запрос: Q_k — тоже, но храним как множество

Соответствие:

- Зафиксируем запрос Q_k
- Пусть есть распределение вероятностей на всех текстах “быть релевантным запросу Q_k ”: обозначаем $P(R|Q_k, D)$
- Пусть есть распределение вероятностей на всех текстах “быть НЕрелевантным запросу Q_k ”: обозначаем $P(\bar{R}|Q_k, D)$
- Функцией соответствия будет их отношение (или логарифм этой дроби): $\frac{P(R|Q_k, D)}{P(\bar{R}|Q_k, D)}$

Воспользуемся теоремой Байеса ($P(a|b) = P(b|a)\frac{P(a)}{P(b)}$):

$$\frac{P(R|Q_k, D)}{P(\bar{R}|Q_k, D)} = \frac{P(R|Q_k)}{P(\bar{R}|Q_k)} \frac{P(D|R, Q_k)}{P(D|\bar{R}, Q_k)}$$

Первый сомножитель одинаков для всех документов.

Предполагая независимость всех слов, второй

сомножитель можно представить как произведение:

$$\prod_{i=1}^n \frac{P(x_i = d_i|R, Q_k)}{P(x_i = d_i|\bar{R}, Q_k)}$$

9 / 29

$$\prod_{i \in Q_k \cap D} \frac{p_{ik}(1 - q_{ik})}{q_{ik}(1 - p_{ik})} \prod_{i \in Q_k} \frac{1 - p_{ik}}{1 - q_{ik}}$$

Второй сомножитель одинаков для всех документов.

Забудем про него и возьмем логарифм от первого:

$$\sum_{i \in Q_k \cap D} c_{ik}, \quad \text{где } c_{ik} = \log \frac{p_{ik}(1 - q_{ik})}{q_{ik}(1 - p_{ik})}$$

11 / 29

$$p_{ik} = \frac{r_i}{r} \quad \text{и} \quad q_{ik} = \frac{f_i - r_i}{f - r},$$

Тут r — общее число документов, r_i — число релевантных документов, f_i — число документов, содержащих слово i , а f — общее число документов со словом i .

13 / 29

Любая поисковая система содержит три базовые части:

- Робот (он же краулер, спайдер или индексатор)
- Базы данных
- Клиент (обработка запросов)

$$\prod_{i=1}^n \frac{P(x_i = d_i|R, Q_k)}{P(x_i = d_i|\bar{R}, Q_k)}$$

Введем обозначения: $p_{ik} = P(x_i = 1|R, Q_k)$ и $q_{ik} = P(x_i = 1|\bar{R}, Q_k)$. Предположим, что для каждого слова i , не входящего в запрос,

$$p_{ik} = q_{ik}$$

Теперь мы можем переписать нашу дробь:

$$\prod_{i \in Q_k \cap D} \frac{p_{ik}(1 - q_{ik})}{q_{ik}(1 - p_{ik})} \prod_{i \in Q_k} \frac{1 - p_{ik}}{1 - q_{ik}}$$

10 / 29

$$\sum_{i \in Q_k \cap D} c_{ik}, \quad \text{где } c_{ik} = \log \frac{p_{ik}(1 - q_{ik})}{q_{ik}(1 - p_{ik})}$$

Для использования полученной формулы нужно знать p_{ik} и q_{ik} .

Рецепт: пусть у нас уже есть некий набор текстов, про которые мы знаем, релевантны они запросу Q_k или нет. Тогда мы можем использовать формулы:

$$p_{ik} = \frac{r_i}{r} \quad \text{и} \quad q_{ik} = \frac{f_i - r_i}{f - r},$$

Угадываете смысл обозначений?

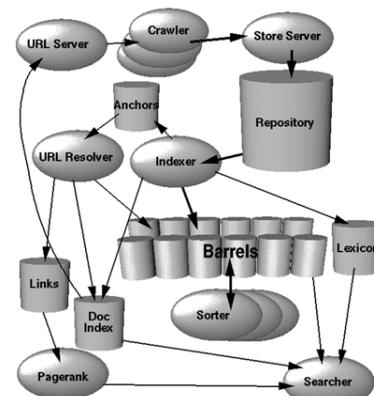
12 / 29

В каком формате запоминать интернет-страницы?

В какой структуре данных их хранить?

Как обрабатывать запрос пользователя?

14 / 29



16 / 29

15 / 29

Прямой индекс — записи отсортированы по документам

- Номер документа
- Отсортированный список слов
- Для каждого слова: первые несколько вхождений, частота вхождений, формат вхождений

Обратный индекс — записи отсортированы по словам

- Номер слова
- Отсортированный список документов
- Для каждого документа: информация о вхождении

Как работает клиент?

- Разбирает запрос на слова
- Переводит слова в их идентификаторы
- Для каждого слова находит в обратном индексе список документов, его содержащих
- Одновременно бежит по этим спискам, ища общий документ
- Для каждого найденного документа вычисляет степень релевантности
- Сортирует образовавшийся список по релевантности

Качество поиска

Как оценить качество поиска?

- Полнота:** отношение количества найденных релевантных документов к общему количеству релевантных документов
- Точность:** доля релевантных документов в общем количестве найденных документов
- Benchmarks:** показатели системы на контрольных запросах и специальных коллекциях документов
- Оценка экспертов**

Не пропустите, 23 ноября — приглашенная лекция Игоря Некрестьянова “Оценка качества интернет-поиска”

Часть III

Как определить ссылочную популярность страницы (PageRank)?

Как быстро вычислить приближение PageRank?



PageRank: постановка задачи

Хотим для каждой страницы сосчитать показатель ее “качества”.

Идея [Брин, 1998]: Определить рейтинг страницы через количество ведущих на нее ссылок и рейтинг ссылающихся страниц

Другие методы:

- Учет частоты обновляемости страницы
- Учет посещаемости
- Учет регистрации в каталоге-спутнике поисковой системы

Модель случайного блуждания

Сеть:

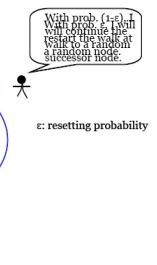
- Вершины
- Оrientированные ребра (ссылки)

Передвижение пользователей по сети

- Стартуем в случайной вершине
- С вероятностью ε переходим в случайную вершину
- С вероятностью $1 - \varepsilon$ переходим по случайному исходящему ребру

Предельные вероятности

- Для каждого k можно определить $PR_k(i)$ как вероятность оказаться в вершине i через k шагов
- Факт: $\lim_{k \rightarrow \infty} PR_k(i) = PR(i)$, то есть для каждой вершины есть предельная вероятность находится именно в ней



Основное уравнение PageRank

Пусть T_1, \dots, T_n — вершины, из которых идут ребра в i , $C(X)$ — обозначение для исходящей степени вершины X .

Утверждение: $PR(i) = \varepsilon/N + (1 - \varepsilon) \sum_{j=1}^n \frac{PR(T_j)}{C(T_j)}$

Кто может доказать?

По определению $PR_k(i)$ верно следующее:

$$PR_0(i) = 1/N$$

$$PR_k(i) = \varepsilon/N + (1 - \varepsilon) \sum_{j=1}^n \frac{PR_{k-1}(T_j)}{C(T_j)}$$

Нужно просто перейти к пределу!

Практическое решение: вместо $PR(i)$ используют $PR_{50}(i)$, вычисленное по итеративной формуле.

25 / 29

PageRank как собственный вектор

Определим матрицу L :

Если нет ребра из i в j , то $L_{ij} := \varepsilon/N$

Если ребро есть, то $L_{ij} := \varepsilon/N + (1 - \varepsilon) \cdot \frac{1}{C(j)}$

Введем обозначения:

$$\overline{PR}_k = (PR_k(1), \dots, PR_k(N))$$

$$\overline{PR} = (PR(1), \dots, PR(N))$$

Получаются соотношения:

$$PR_k = L^k PR_0$$

$$PR = L PR$$



26 / 29

Задачи

Докажите, что расстояние между векторами $PR_k(i), PR(i)$ экспоненциально быстро (по k) стремится к нулю

25 / 29

Главные моменты

Сегодня мы узнали:

- Модели информационного поиска: булевская, векторная, вероятностная
- Поисковая система (1) скачивает и анализирует интернет-страницы, (2) записывает в базу и сортирует ее, (3) обрабатывает запросы, выводя лучшие страницы по функции релевантности
- PageRank — это предельная вероятность оказаться на web-сайте в результате случайного блуждания по ссылкам.

Вопросы?

27 / 29

28 / 29

Источники

Страница курса <http://logic.pdmi.ras.ru/~yura/internet.html>

Использованные материалы:

- Sergey Brin and Larry page
The Anatomy of Search Engine
<http://www-db.stanford.edu/pub/papers/google.pdf>
- Илья Сегалович
Как работают поисковые системы
<http://company.yandex.ru/articles/article10.html>
- Langville and Meyer
Deeper Inside PageRank
http://meyer.math.ncsu.edu/Meyer/PS_Files/DeeperInsidePR.pdf
- Norbert Fuhr
Probabilistic Models in Information Retrieval
<http://www.is.informatik.uni-duisburg.de/bib/fulltext/ir/Fuhr:92.pdf>

29 / 29