

Яндекс на РОМИП-2004

Илья Сегалович, Михаил Маслов
{iseg, maslov}@yandex-team.ru

Поиск и ранжирование

- Архитектурные особенности
- Фильтрация
- Ранжирование
- Результаты на РОМИП-2004



Архитектурные особенности

- ❑ Инвертированный массив полных словопозиций
- ❑ Обработка: одновременный проход (Document Ordered)
- ❑ Субиндекс: self-indexing inverted files
- ❑ Операции пересечения: полная словопозиция+контекстные ограничения+субиндекс



Фильтрация

- Контекстные ограничения
 - Многместный оператор AND
 - Кворум: Коэффициент мягкости
(несколько **op1** слов **op2** запроса) // **softness**
 - Контекст документа; предложения;
назначенный пользователем; назначенные
системой
 - Контекст, назначенный системой
 - Синтаксический разбор
 - Статистика слов в индексе



Кворум

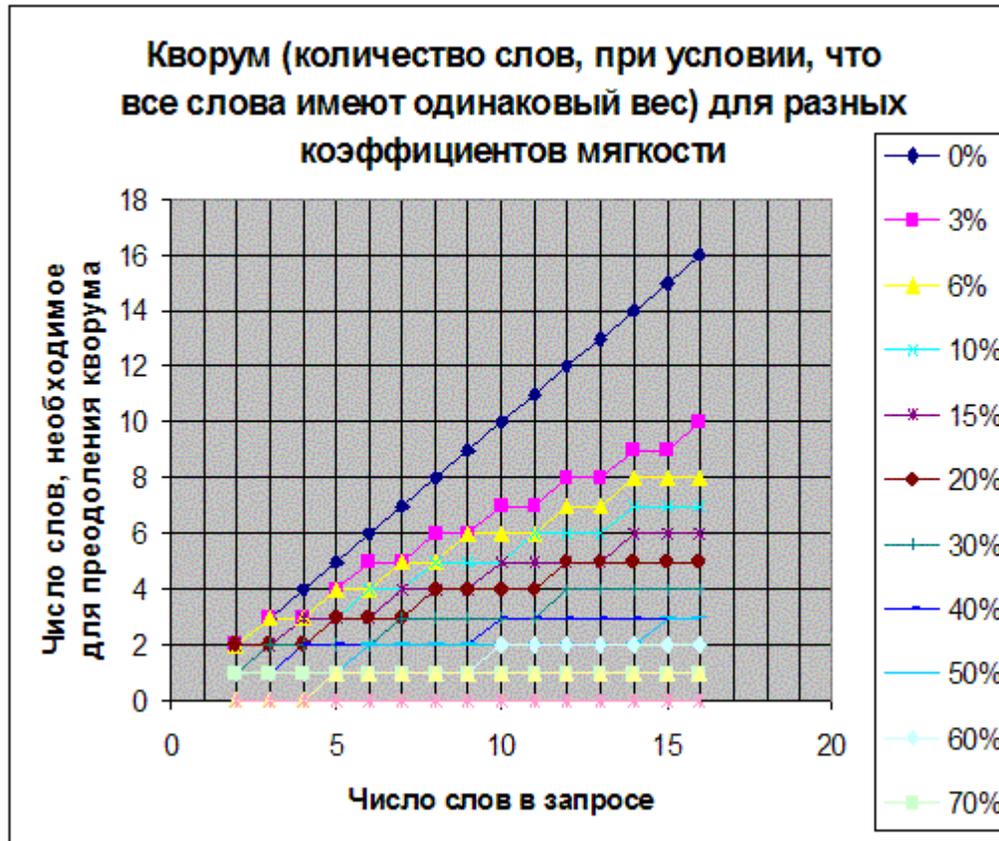
- Формула для доли веса

$$QuorumWeight = (1 - Softness)^{\frac{1}{\sqrt{QL-1}}}$$

где QL – число слов в запросе
 $Softness$ – число от 0 до 1



Кворум



Принципы ранжирования

- Внутрیدокументная частота (TF) по релевантным пассажам
 - Корректное нормирование на длину документа
- Вычисляемый вес каждой словопозиции
 - Пример, где второй пассаж ранжируется выше
[aa ___ BB ___ cc dd ee]
[aa BB cc dd ___ ___ ee]



Ранжирование: контекстуальное сходство

- ❑ Объемлющие пассажи игнорируются
- ❑ Считается вес для каждой опоры: вес пассажи равен сумме весов опор
- ❑ Ранг неполных пассажиров строго меньше ранга полных
- ❑ Вес опоры убывает с ростом расстояния между опорами



Ранжирование: форматирование текста

- Вес слова учитывает его вхождение в заголовки
- Бонус для полных насыщенных пассажей
- Учет при индексировании



Результат по прогонам

- Выбранные параметры
 - Softness = 6
 - Без группировки по хостам (для веб-коллекции)
 - Документный контекст
- Результаты
 - (на словах)

