

Санкт-Петербургский Государственный Университет  
Математико-механический факультет  
Кафедра системного программирования

## Рекомендации треков в социальных сетях

Александр Александрович Дзюба, 661 группа

*Магистерская диссертация*

Научный руководитель: к.ф.-м.н., Д.Ю. Бугайченко

Рецензент: к.ф.-м.н., доцент И.П. Соловьев

# Рекомендательные системы

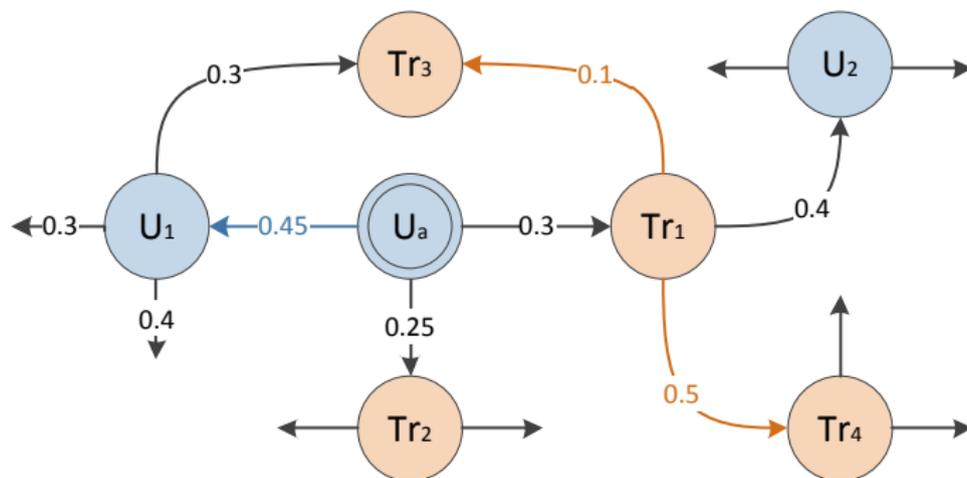
- ▶ Предсказывают, какой контент понравится пользователю
- ▶ Прогноз рассчитывается на основе сетевого профиля
  - ▶ С оценками предметов
  - ▶ Историей взаимодействия с предметами (количество прослушиваний, просмотров, фактов покупки)
  - ▶ С указанными предпочтениями (жанры, исполнители)

# Классические методы

- ▶ **Коллаборативная фильтрация** работает с матрицей оценок предметов, выставленных пользователями
  - ▶ *User-based* – поиск похожих пользователей и использование их оценок для предсказания
  - ▶ *Item-based* – поиск предметов, которые нравятся пользователям вместе
- ▶ **Рекомендация по содержанию** сопоставляет известные интересы пользователя и описание контента
  - ▶ Применимость сильно ограничена

# Алгоритм Random Walk with Restarts

- ▶ По качеству превосходит коллаборативную фильтрацию
- ▶ Граф социальной сети



- ▶ Вычисление степени «связанности» вершин с помощью случайного обхода

# Алгоритм Random Walk with Restarts

Расчет рекомендаций:

$$\mathbf{p}^{(t+1)} = (1 - a)\mathbf{S}\mathbf{p}^{(t)} + a\mathbf{q}$$

$\mathbf{p}^{(t)}$  – вектор предпочтений на шаге  $t$

$\mathbf{S}$  – матрица смежности социального графа

$a$  – вероятность возврата в начало

$\mathbf{q}$  – вектор возврата

UU	UTr	UTg
UTr	0	TgTr
UTg	TgTr	0

## Постановка задачи

- ▶ Реализовать рекомендательную систему на основе алгоритма Random Walk with Restarts
- ▶ Использовать традиционные методы расчёта рекомендации для составления графа социальной сети
- ▶ Оценить качество рекомендаций для разных способов построения графа, используя данные реальных социальных сетей
- ▶ Предложить метод ускорения расчёта рекомендаций для применения в крупных социальных сетях
- ▶ Оценить время и качество рекомендаций при использовании предложенного метода

# Тестовые данные

## Last.fm

- ▶ 3 тыс. пользователей
- ▶ 30 тыс. треков
- ▶ 800 тыс. связей пользователь-трек
- ▶ 27 млн. прослушиваний

# Улучшение качества

- ▶ Замена социальных связей близостью вкусов
  - ▶ Расчет схожести векторов-рейтингов
  - ▶ Косинус угла между векторами, коэффициент Пирсона и другие
  - ▶ Реализованы в Apache Mahout
- ▶ Добавление дуг между схожими треками
- ▶ Раздельное нормирование столбцов  $S$
- ▶ Оценки качества
  - ▶ Recall-Precision кривые
  - ▶ Half-life utility

## Оценка качества, Half-life utility

- ▶ Разделение истории прослушиваний на тренировочное и проверочное множество
- ▶ Элементы проверочного множества ( $Q$ ) заранее неизвестны и используются для определения релевантности результата

$$HL_{a,c} = \frac{\sum_j r_{a,j}}{2^{(j-1)(c-1)}}, \text{ где } r_{a,j} = \begin{cases} 0, & \text{если } v_j \notin Q_a; \\ 1, & \text{если } v_j \in Q_a. \end{cases}$$

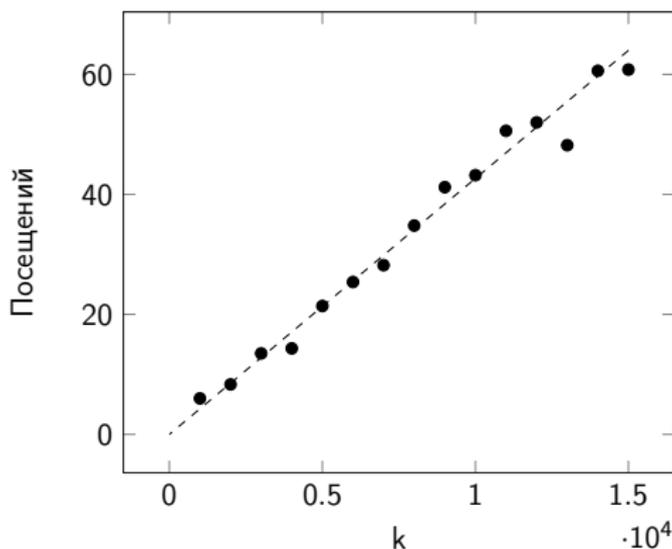
$c$  – «период полураспада»

$v_j$  –  $j$ -й рекомендованный трек

- ▶ Удалось существенно улучшить качество рекомендаций согласно данной метрике
  - ▶ для  $c = 10$ : с 2.675 до 4.15

# Симуляция

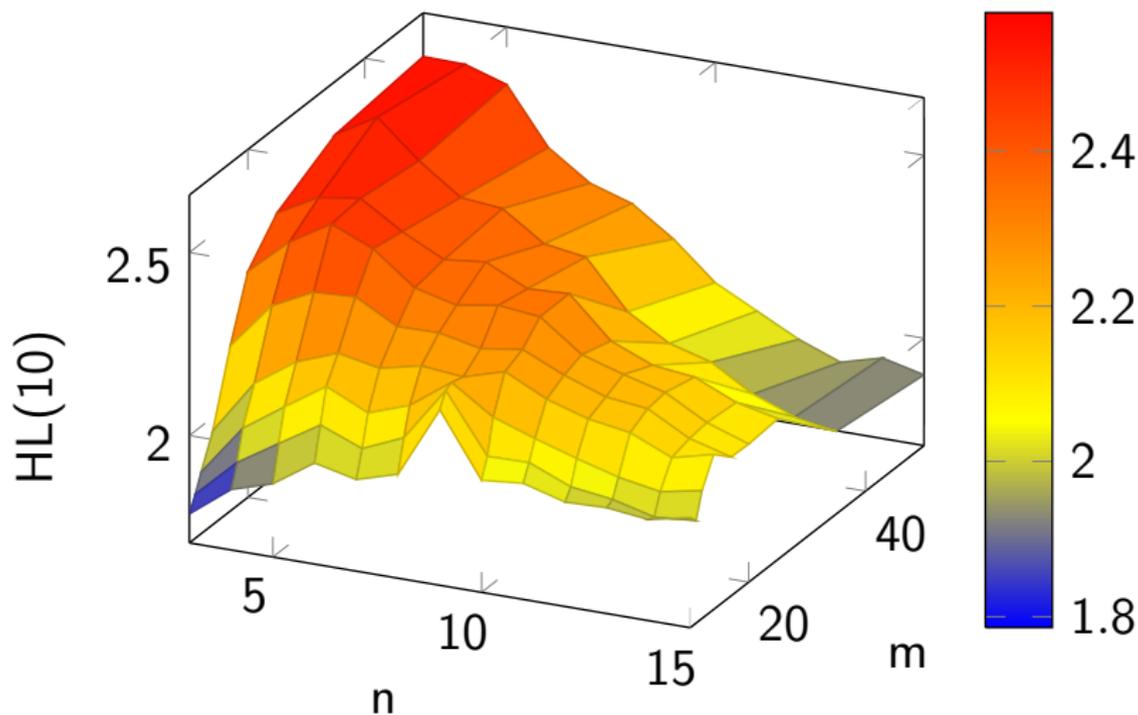
- ▶ Считается количество посещений вершин-треков при случайном обходе из  $k$  шагов
- ▶ При  $k < 10^5$  необходимая точность не достигается



# Персональные подграфы

- ▶ Подграф строится сразу после запроса рекомендаций:
  1. Включаются наиболее близкие пользователю объекты
  2. Аналогичные действия для объектов, добавленных на 1 шаге
- ▶ Время и качество расчёта рекомендаций зависит от размера включения вершин и дуг

## Зависимость качества от размера включения вершин



$n$  включаемых вершин на 1 шаге  
 $m$  включаемых вершин на 2 шаге

# Результаты

- ▶ Реализована Java-платформа для конфигурирования и тестирования рекомендательных систем
- ▶ Предложена модификация алгоритма Random Walk with Restarts, дающая более качественные рекомендации
- ▶ Предложен способ упрощения оригинального алгоритма, проведено исследование качества предложенного метода
- ▶ Приведены результаты симуляции алгоритма Random Walk with Restarts
- ▶ Описанные методы протестированы на наборе данных социальной сети Last.fm