Методы коллаборативной фильтрации и их применения

К. В. Воронцов
vokov@forecsys.ru
http://www.ccas.ru/voron

Вычислительный Центр им. А. А. Дородницына РАН;
ЗАО «Форексис»

ВШЭ, семинар Б. Г. Миркина, 10 ноября 2008

Содержание

Определения и обозначения

U — множество субъектов (клиентов, пользователей: users);
R — множество объектов (ресурсов, товаров, предметов: items);
Y — пространство описаний транзакций;

Сырые исходные данные:

$D = (u_i, r_i, y_i)_{i=1}^m \in U \times R \times Y$ — протокол транзакций;

Агрегированные данные:

$F = \|f_{ur}\|$ — матрица кросс-табуляции размера $|U| \times |R|$,
где $f_{ur} = \text{aggr}\{(u_i, r_i, y_i) \in D \mid u_i = u,\ r_i = r\}$

Задачи:

- прогнозирование незаполненных ячеек f_{ur};
- оценивание сходства: $\rho(u, u')$, $\rho(r, r')$, $\rho(u, r)$;
- выявление скрытых интересов $p(t|u)$, $q(t|r)$ относительно заданного либо неизвестного набора тем $t = 1, \ldots, T$.

Пример 1. Рекомендующая система на основе бинарных данных

U — пользователи Интернет;
R — ресурсы (сайты, документы, новости, и т.п.);
$f_{ur} = [\text{пользователь } u \text{ посетил ресурс } r]$;

Основная гипотеза Web Usage Mining:

- Действия (посещения) пользователя характеризуют его интересы, вкусы, привычки, возможности.

Задачи персонализации:

- выдать оценку ресурса r для пользователя u;
- выдать пользователю u ранжированный список рекомендуемых ресурсов;
- сгенерировать для ресурса r список близких ресурсов.

Пример 2. Рекомендующая система на основе бинарных данных

U — клиенты интернет-магазина (amazon.com и др.);
R — товары (книги, видео, музыка, и т.п.);
$f_{ur} = [\text{клиент } u \text{ купил товар } r]$;

Задачи персонализации предложений:

- выдать оценку товара r для клиента u;
- выдать клиенту u список рекомендуемых товаров;
- предложить скидку на совместную покупку (cross-selling);
- информировать клиента о новом товаре (up-selling);
- сегментировать клиентскую базу;
  выделить целевые аудитории по интересам.

Пример 3. Рекомендующая система на основе рейтингов

U — клиенты интернет-магазина (netflix.com и др.);
R — товары (книги, видео, музыка, и т.п.);
f_{ur} = рейтинг, который клиент u выставил товару r;

Задачи персонализации предложений — те же.

Пример: конкурс Netflix [www.netflixprize.com]

- с октября 2006 до сих пор; главный приз — $\$10^6$;
- $|U| = 0.48 \cdot 10^6$; $|R| = 1.7 \cdot 10^4$;
- 10^8 рейтингов $\{1, 2, 3, 4, 5\}$;
- точность прогнозов оценивается по тестовой выборке D':

$$\text{RMSE}^2 = \sum_{(u,r) \in D'} \left(f_{ur} - \hat{f}_{ur}\right)^2;$$

- требуется: уменьшить RMSE с 0.9514 до 0.8563 (на 10%)
  текущий рекорд от 30.09.2008: 0.8616 (9.44%).

Пример 4. Анализ текстов

U — текстовые документы (статьи, новости, и т.п.);
R — ключевые слова или выражения;
f_{ur} = частота встречаемости слова r в тексте u.

Задачи анализа текстов:

- кластеризация текстов: сгруппировать тексты по тематике;
- определить тематику нового текста (например, новости);
- найти тексты той же тематики, что данный текст;
  ранжировать найденные тексты по сходству;
- построить иерархический каталог текстов;
  описать каждый раздел набором ключевых слов.

Пример 5. Социальные сети, форумы, блоги

U — пользователи;
R — текстовые документы (форумы, блоги);
K — ключи (ключевые слова или выражения);
$f_{ur} = [\text{пользователь } u \text{ участвует в } r]$;
$g_{rk} =$ частота встречаемости ключа k в тексте r;
$h_{uv} = [\text{пользователю } u \text{ интересен пользователь } v]$.

Некоторые задачи анализа социальной сети:

- рекомендовать пользователю интересные ему блоги, найти единомышленников (like-minded people);
- охарактеризовать интересы пользователя ключами;
- найти все блоги по данным или похожим ключам;
- найти все блоги, похожие на данный;
- построить иерархический тематический каталог блогов.

Два основных подхода

1. **Модели, основанные на хранении исходных данных**
   (Memory-Based Collaborative Filtering)
   - хранение всей исходной матрицы данных F;
   - сходство клиентов — это корреляция строк матрицы F;
   - сходство объектов — это корреляция столбцов матрицы F.

2. **Латентные модели**
   (Latent Models for Collaborative Filtering)
   - оценивание профилей клиентов и объектов
     (*профиль — это вектор скрытых характеристик*);
   - хранение профилей вместо хранения F;
   - сходство клиентов и объектов — это сходство их профилей.

Подборки статей по коллаборативной фильтрации:

jamesthornton.com/cf

www.adastral.ucl.ac.uk/∼junwang/CollaborativeFiltering.html

Тривиальная рекомендующая система

«клиенты, купившие r_0, также покупали $R(r_0)$» [Amazon.com]

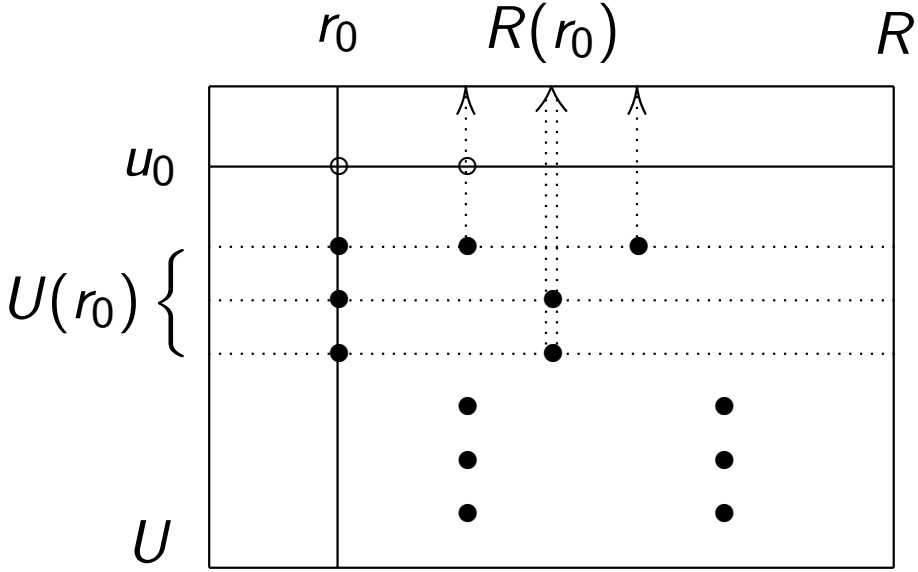

1. $U(r_0) := \left\{ u \in U \;\middle|\; f_{ur_0} \neq \varnothing,\ u \neq u_0 \right\}$;
2. $R(r_0) := \left\{ r \in R \;\middle|\; B(r) = \frac{|U(r_0) \cap U(r)|}{|U(r_0) \cup U(r)|} > 0 \right\}$,
   где $B(r) =$ — одна из возможных мер близости r к r_0;
3. отсортировать $r \in R(r_0)$ по убыванию $B(r)$, взять top N.

Тривиальная рекомендующая система

«клиенты, купившие r_0, также покупали $R(r_0)$» [Amazon.com]

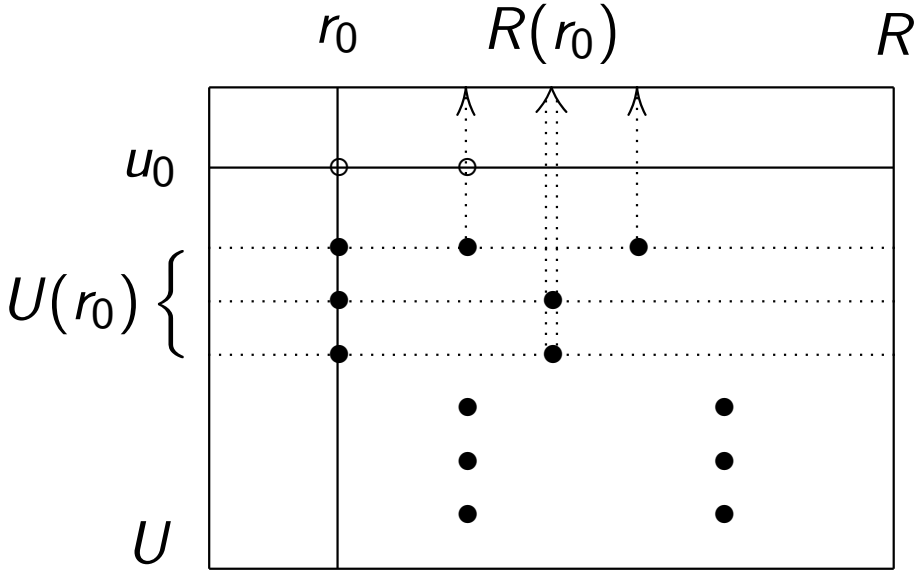

Недостатки:

- рекомендации тривиальны (предлагается всё наиболее популярное);
- не учитываются интересы конкретного пользователя u_0;
- не учитывается степень сходства ресурсов r и r_0;
- проблема «холодного старта»;
- надо хранить всю матрицу F.

От клиента (user-based CF)

«клиенты, похожие на u_0, также покупали $R(u_0)$»

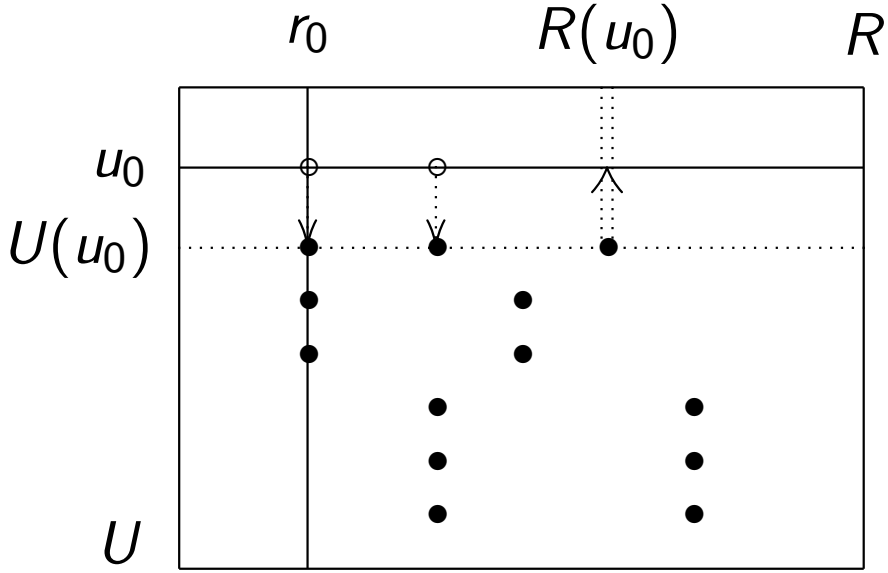

1. $U(u_0) := \left\{ u \in U \;\middle|\; \text{corr}(u_0, u) > \alpha \right\}$;
2. $R(u_0) := \left\{ r \in R \;\middle|\; B(r) = \frac{|U(r_0) \cap U(r)|}{|U(u_0) \cup U(r)|} > 0 \right\}$;
3. отсортировать $r \in R(u_0)$ по убыванию $B(r)$, взять top N;

От клиента (user-based CF)

«клиенты, похожие на u_0, также покупали $R(u_0)$»

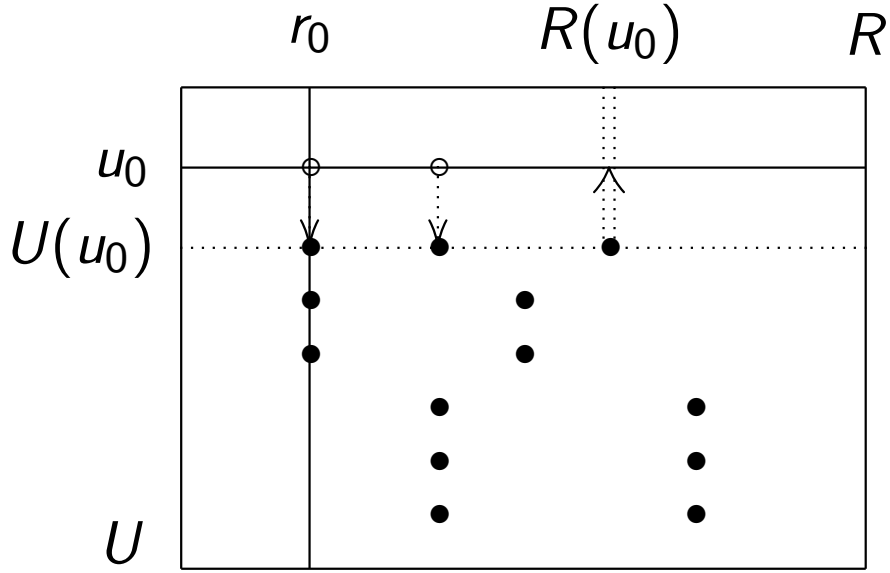

Недостатки:

- ~~рекомендации тривиальны~~;
- ~~не учитываются интересы конкретного пользователя u_0~~;
- не учитывается степень сходства ресурсов r и r_0;
- проблема «холодного старта»;
- надо хранить всю матрицу F;
- нечего рекомендовать нетипичным/новым пользователям.

От объекта (item-based CF)

«вместе с объектами,
которые покупал u_0,
часто покупают $R(u_0)$»

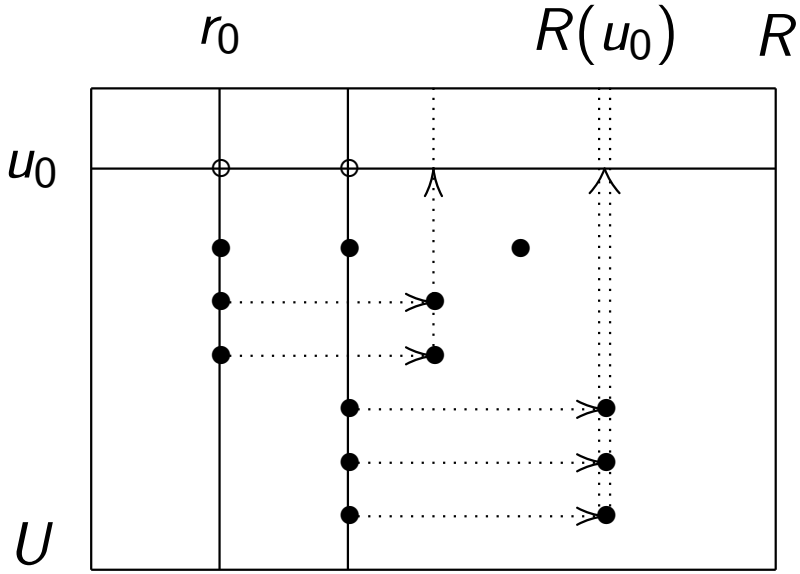

1. $R(u_0) := \{r \in R \mid \exists r_0 : f_{u_0 r_0} \neq \varnothing$ и $B(r) = \mathrm{corr}(r, r_0) > \alpha\}$;
2. сортировка $r \in R(u_0)$ по убыванию $B(r)$, взять top N;

От объекта (item-based CF)

«вместе с объектами,
которые покупал u_0,
часто покупают $R(u_0)$»

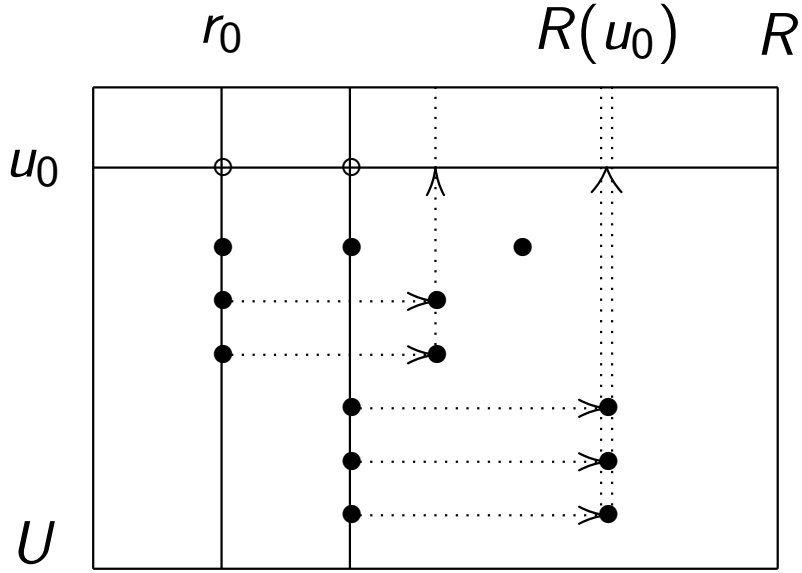

Недостатки:

- рекомендации часто тривиальны (нет коллаборативности);
- ~~не учитывается степень сходства ресурсов r и r_0~~;
- проблема «холодного старта»;
- надо хранить попарные корреляции между объектами;
- ~~нечего рекомендовать нетипичным пользователям~~.

Резюме по Memory-Based методам

Преимущества:

- Легко понять;
- Легко реализовать.

Недостатки:

- Не хватает теоретического обоснования:
  придумано много способов оценить сходство...
  придумано много гибридных (item-user-based) методов...
  ...не ясно, как выбрать лучший;
- Все методы требуют хранения огромной матрицы F.

Далее:

- *Латентные модели* — лишены этих недостатков.

Понятие латентной модели

Латентная модель: по данным D оцениваются векторы:
$(p_{su})_{s \in S}$ — профили клиентов $u \in U$;
$(q_{tr})_{t \in T}$ — профили объектов $r \in R$.

Типы латентных моделей (основные идеи):

1. Ко-кластеризация:
   — жёсткая: $\begin{cases} p_{su} = [\text{клиент } u \text{ принадлежит кластеру } s]; \\ q_{tr} = [\text{объект } r \text{ принадлежит кластеру } t]; \end{cases}$
   — мягкая: p_{su}, q_{tr} — степени принадлежности кластерам.
2. Матричная факторизация: $S = T$;
   по p_{tu}, q_{tr} должны восстанавливаться f_{ur}.
3. Вероятностные (байесовские) модели: $S = T$;
   $p_{tu} = p(t|u)$, $q_{tr} = q(t|r)$.

Ко-кластеризация (бикластеризация)

Пусть f_{ur} — рейтинги;

$G = \big(g(u)\big)_{u \in U}$ — кластеризации клиентов;

$H = \big(h(r)\big)_{r \in R}$ — кластеризации объектов;

Модель усреднения по блокам (Block Average):

$$\hat{f}_{ur}(G, H) = \bar{f}_{g(u),h(r)} + (\bar{f}_u - \bar{f}_{g(u)}) + (\bar{f}_r - \bar{f}_{h(r)});$$

$\bar{f}_{g(u),h(r)}$ — средние по ко-кластерам;

$\bar{f}_{g(u)}$ и $\bar{f}_{h(r)}$ — средние по кластерам;

$\bar{f}_u$ и $\bar{f}_r$ — средние по клиентам и по объектам;

Функционал качества кластеризации:

$$\sum_{(u,r) \in D} \big(\hat{f}_{ur}(G, H) - f_{ur}\big)^2 \to \min_{G,H};$$

Ко-кластеризация: простой алгоритм

Алгоритм BBAC (Bregman Block Average Co-clustering)

- Инициализировать случайные кластеризации $g(u)$, $h(r)$;
- Повторять пока кластеризации изменяются:
  1. Вычислить все средние:
     $\bar{f}_{g(u),h(r)}$; $\bar{f}_{g(u)}$, $\bar{f}_{h(r)}$; $\bar{f}_u$; $\bar{f}_r$;
  2. Вычислить новые кластеризации для всех клиентов $u \in U$:
     $g(u) := \arg\min_g \sum_{r \in D_u} \left(\hat{f}_{ur}(g, H) - f_{ur}\right)^2$;
  3. Вычислить новые кластеризации для всех объектов $r \in R$:
     $h(r) := \arg\min_h \sum_{u \in D_r} \left(\hat{f}_{ur}(G, h) - f_{ur}\right)^2$;

George T., Merugu S. A scalable collaborative filtering framework based on co-clustering // 5-th IEEE int. conf. on Data Mining, 2005, Pp. 27–30.

Banerjee A., et al. A generalized maximum entropy approach to Bregman co-clustering and matrix approximation // 10-th KDDM, 2004, Pp. 509–514.

Матричные разложения

T — множество тем (интересов): $|T| \ll |U|$, $|T| \ll |R|$;

p_{tu} — неизвестный *профиль клиента* u; $P = (p_{tu})_{|T| \times |U|}$;

q_{tr} — неизвестный *профиль объекта* r; $Q = (q_{tr})_{|T| \times |R|}$;

Задача: найти разложение $f_{ur} = \sum_{t \in T} \lambda_t p_{tu} q_{tr}$; $F = P^{\mathrm{T}} \Lambda Q$;

Методы решения:

SVD — сингулярное разложение (плохо интерпретируется!);

NNMF — неотрицательное разложение: $p_{tu} \geqslant 0$, $q_{tr} \geqslant 0$;

Вероятностная интерпретация:

$$\underbrace{p(u,r)}_{f_{ur}?} = \sum_{t \in T} \underbrace{p(t)}_{\lambda_t} \cdot \underbrace{p(u|t)}_{p_{tu}} \cdot \underbrace{q(r|t)}_{q_{tr}};$$

$$q(t|r) = \frac{q_{tr} p(t)}{\sum_{\tau \in T} q_{\tau r} p(\tau)}; \quad p(t|u) = \frac{p_{tu} p(t)}{\sum_{\tau \in T} p_{\tau u} p(\tau)}$$

Байесовская модель посещений

T — множество тем (интересов);
$p_{tu} = p(t|u)$ — неизвестный *профиль клиента* u;
$q_{tr} = q(t|r)$ — неизвестный *профиль объекта* r;
$p_u = p(u)$ — априорная вероятность клиента u;
$q_r = q(r)$ — априорная вероятность объекта r;

Вероятность посещения (u, r) записывается двумя способами:

$$p(u,r) = \begin{cases} \sum\limits_{t\in T} p_u p_{tu} q(r|t,u); & q(r|t) = \dfrac{q_{tr} q_r}{\sum_{r'\in R} q_{tr'} q_{r'}}; \\ \sum\limits_{t\in T} q_r q_{tr} p(u|t,r); & p(u|t) = \dfrac{p_{tu} p_u}{\sum_{u'\in U} p_{tu'} p_{u'}}; \end{cases}$$

Задача: оценить профили p_{tu}, q_{tr}.

Принцип максимума правдоподобия: $\sum\limits_{i=1}^{m} \ln p(u_i, r_i) \to \max\limits_{p_{tu}, q_{tr}}$.

Общая идея: алгоритм согласования профилей

Повторять итерации, пока профили не сойдутся:

1. Настройка профилей клиентов p_{tu} при фиксированных q_{tr}:

$$\begin{cases} \sum\limits_{i=1}^{m} \ln\left(\sum\limits_{t\in T} p_u p_{tu} q(r|t)\right) \to \max\limits_{p_{tu}}; \\ \sum\limits_{t\in T} p_{tu} = 1, \quad \forall u \in U; \end{cases}$$

2. Настройка профилей объектов q_{tr} при фиксированных p_{tu}:

$$\begin{cases} \sum\limits_{i=1}^{m} \ln\left(\sum\limits_{t\in T} q_r q_{tr} p(u|t)\right) \to \max\limits_{q_{tr}}; \\ \sum\limits_{t\in T} q_{tr} = 1, \quad \forall r \in R; \end{cases}$$

EM-алгоритм (настройка профилей клиентов)

Скрытые переменные $H_{tr}(u) \equiv p(t|r,u)$ — апостериорная вероятность темы t при посещении объекта r клиентом u.

EM-алгоритм:

повторять, пока профили p_{tu} не сойдутся

- **E-шаг** (вычисление скрытых переменных):
  для всех объектов $r \in R$, клиентов $u \in U$, тем $t \in T$

$$H_{tr}(u) := \frac{p_{tu} q(r|t)}{\sum_{t' \in T} p_{t'u} q(r|t')};$$

- **M-шаг** (максимизация правдоподобия):
  для всех клиентов $u \in U$, тем $t \in T$

$$p_{tu} := \frac{1}{D_u} \sum_{r \in D_u} H_{tr}(u), \quad \text{где} \quad D_u = \{r : (u,r) \in D\};$$

Симметризованный EM-алгоритм

Инициализировать профили q_{tr} и p_{tu};
Повторять итерации, пока все профили не сойдутся:

1. Фиксировать q_{tr};
   Вычислить $q(r|t)$ по формуле Байеса;
   Повторять, пока профили клиентов не сойдутся:
   - E-шаг: вычислить скрытые переменные $H_{tr}(u)$;
   - M-шаг: вычислить профили клиентов p_{tu};
2. Фиксировать p_{tu};
   Вычислить $p(u|t)$ по формуле Байеса;
   Повторять, пока профили объектов не сойдутся:
   - E-шаг: вычислить скрытые переменные $H_{tu}(r)$;
   - M-шаг: вычислить профили объектов q_{tr};

Обобщения, модификации, применения

- Если $f_{ur} \in Z = \{1, 2, \ldots, z_{\max}\}$ — рейтинги,
  то вместо $p(u, r) = \mathrm{P}(f_{ur} \neq \varnothing)$ надо оценивать
  $(z_{\max} - 1)$ вероятностей $p_z(u, r) = \mathrm{P}(f_{ur} \leqslant z)$, $z \in Z$;
- Динамическое обновление профилей при пополнении D;
- Иерархические профили;
- Учёт априорной информации через
  начальное приближение профилей:
  - тематический каталог объектов;
  - соц-дем (анкеты) клиентов;
- Унифицированный профиль объектов и клиентов;
- Долгосрочный и краткосрочный профили;
- Оценивание сходства по частям профиля.

Данные поисковой машины Яндекс

Исходные данные:

7 дней работы поисковой машины Яндекс; объём лога 3.6 Гб;
14 606 пользователей;
207 312 запросов;
1 972 636 документов было выдано;
129 600 документов были выбраны пользователями.

Фрагмент лога:

```
10983533211096159 96 (номер пользователя)
    французская кухня (запрос) 1110473322 (время запроса) 113906 0
        http://www.naturel.ru/ (сайт или документ)
        http://www.kuking.net/c7.htm 1110473328 (время клика)
        http://www.cooking-book.ru/national/french/
        ...
    жаренное мясо в вине 1110473174 1349 0
    ...
...
```

Данные поисковой машины Яндекс

Схема эксперимента:

- Отбор наиболее посещаемых сайтов, $|R| = 1024$.
- Отбор наиболее активных пользователей, $|U| = 7300$.
- Введение критериев качества профилей:
  - 400 сайтов заранее классифицированы на $|T| = 12$ тематических классов;
  - Q_1 = доля неправильно восстановленных профилей;
  - Q_2 = число ошибок классификации методом kNN;
- Оптимизация параметров по критерию качества.
- Построение профилей и оценок сходства сайтов.
- Визуализация: глобальные и локальные карты сходства.

Результаты: оптимизация числа итераций и $|T|$

Двух итераций на внутреннем цикле уже достаточно!

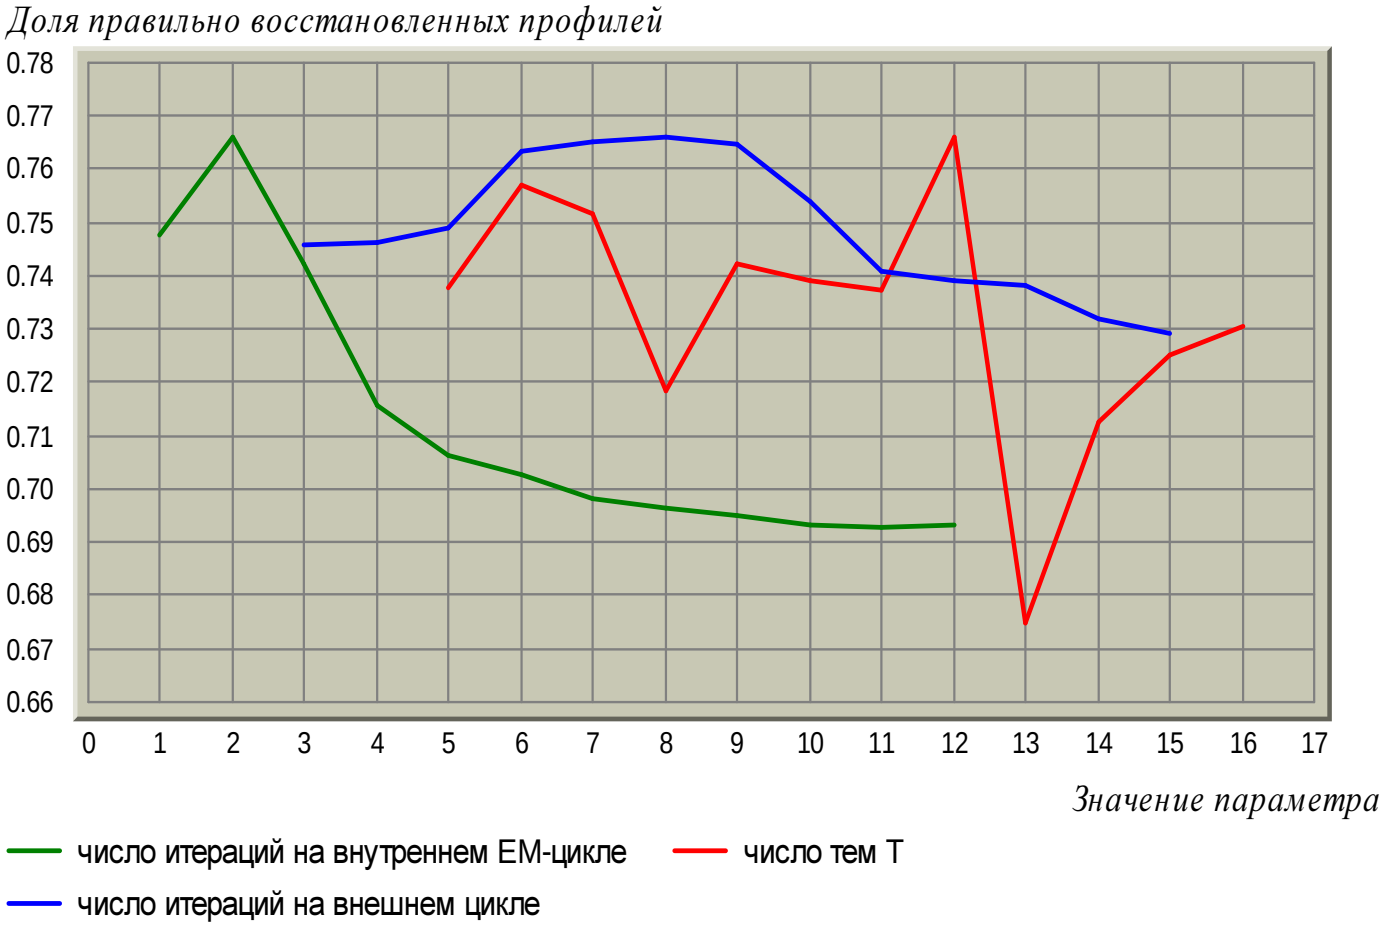

Результаты: подбор меры сходства

оценки сходства по точному тесту Фишера (FET) лучше корреляций, а по профилям — ещё лучше!

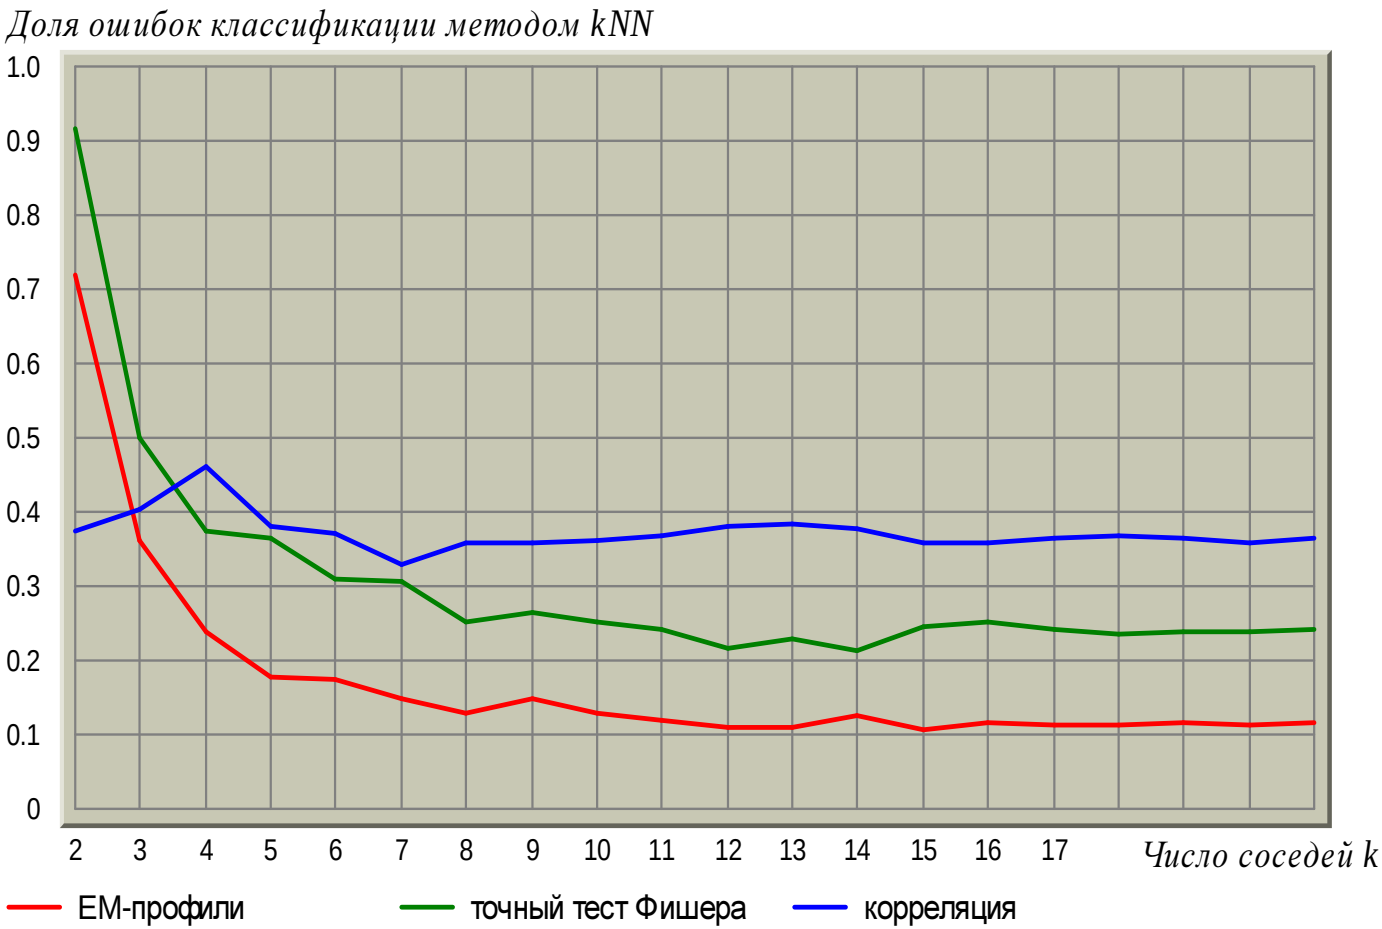

Результаты: карта сходства Интернета

Многомерное шкалирование по FET-оценкам сходства

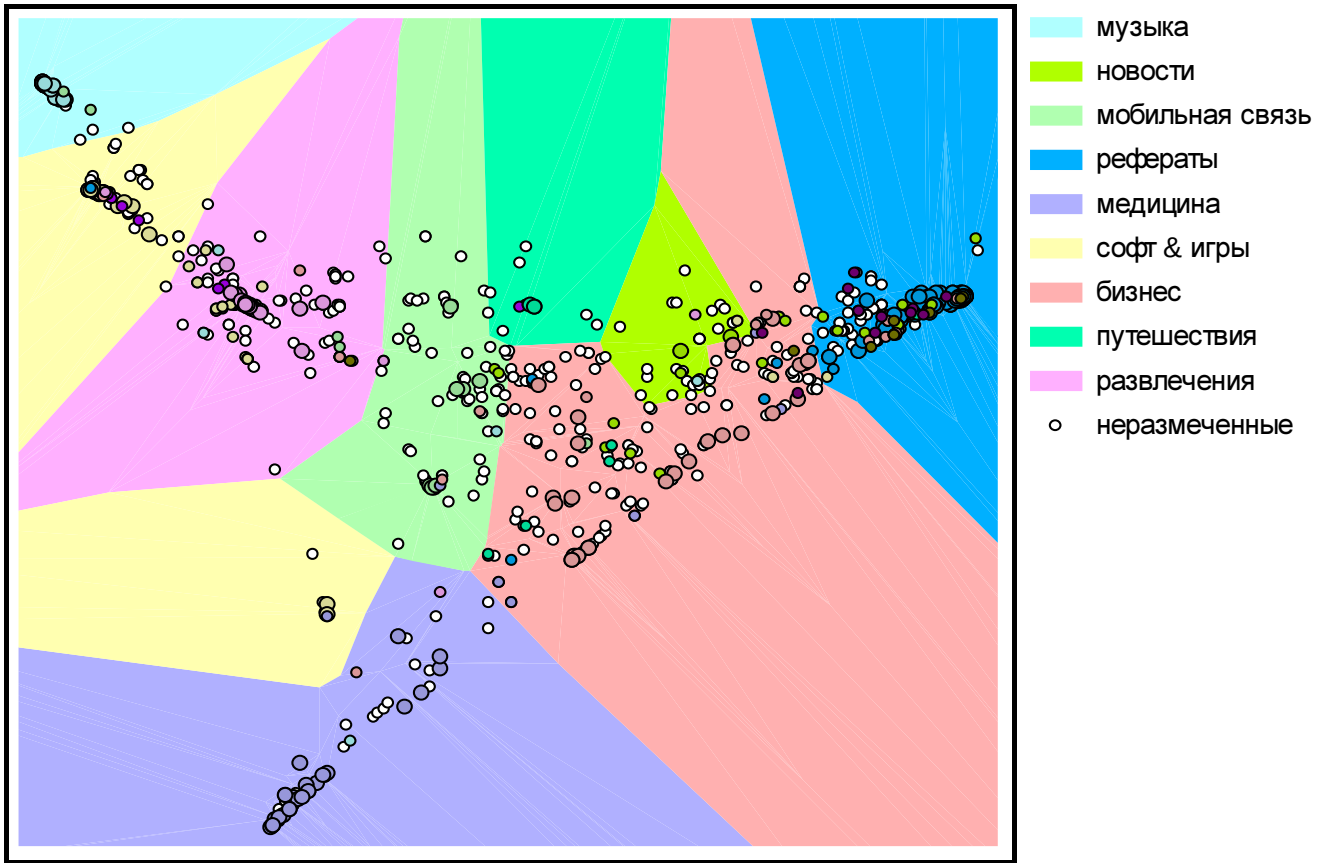

Результат: сайты сами сгруппировались по тематикам!

Что такое «многомерное шкалирование» и «карта сходства»?

Дано: попарные расстояния R_{ij} между n объектами.
Найти: координаты этих объектов на плоскости $(x_i, y_i)_{i=1}^n$:

$$S = \sum_{i<j} \left(\sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} - R_{ij} \right)^2 \to \min_{(x_i, y_i)_{i=1}^n}$$

Карта сходства (Similarity Map) — это средство разведочного анализа многомерных данных:

- точечный график $(x_i, y_i)_{i=1}^n$;
- близким объектам соответствуют близкие точки;
- оси графика не имеют интерпретации;
- возможны искажения.

Результаты: карта сходства Интернета

Многомерное шкалирование по профилям, $|T| = 12$

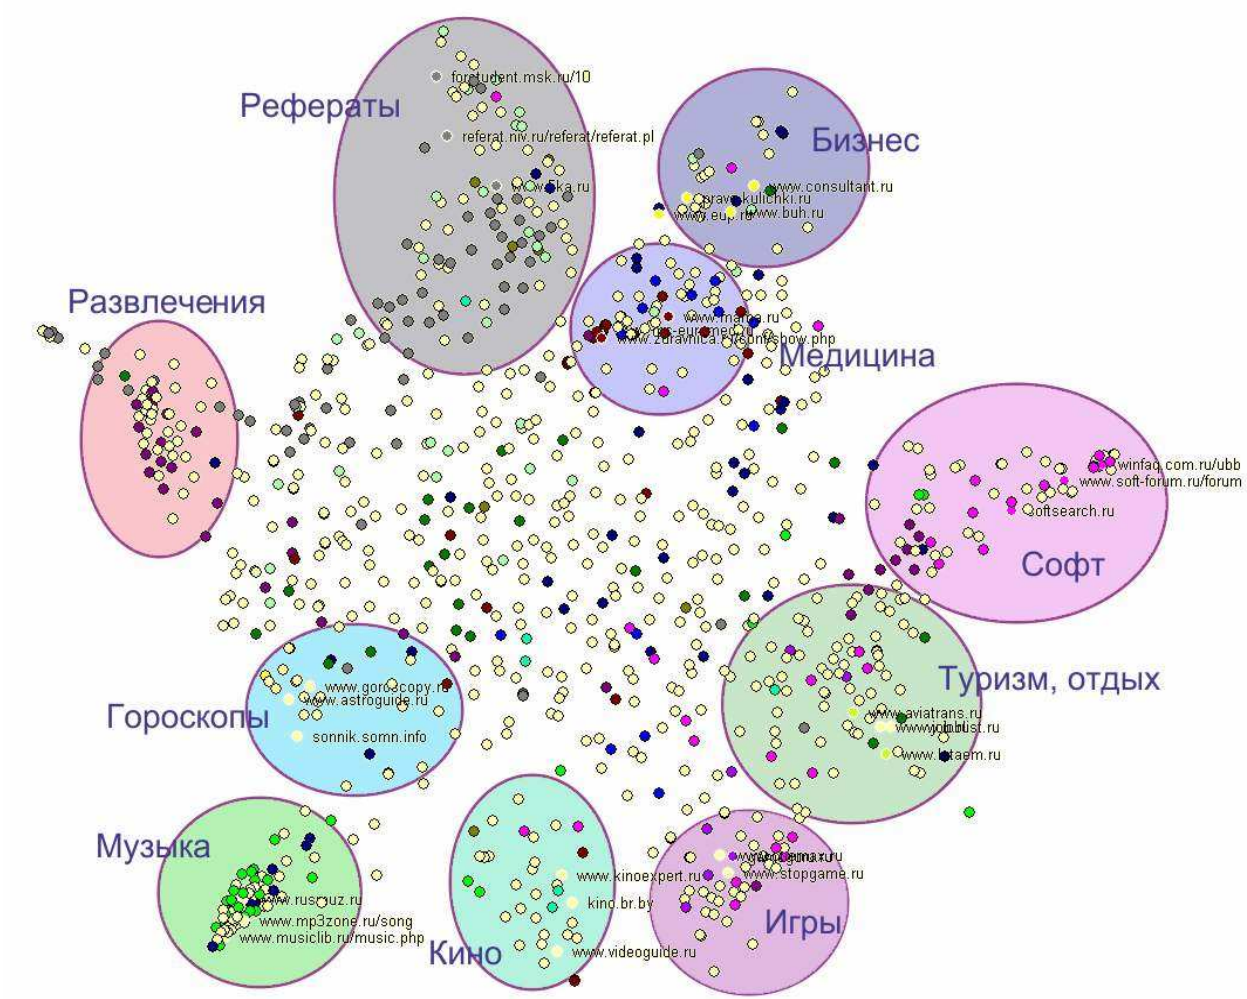

Результаты: локальная карта пользователя

Визуальное представление персональных рекомендаций:

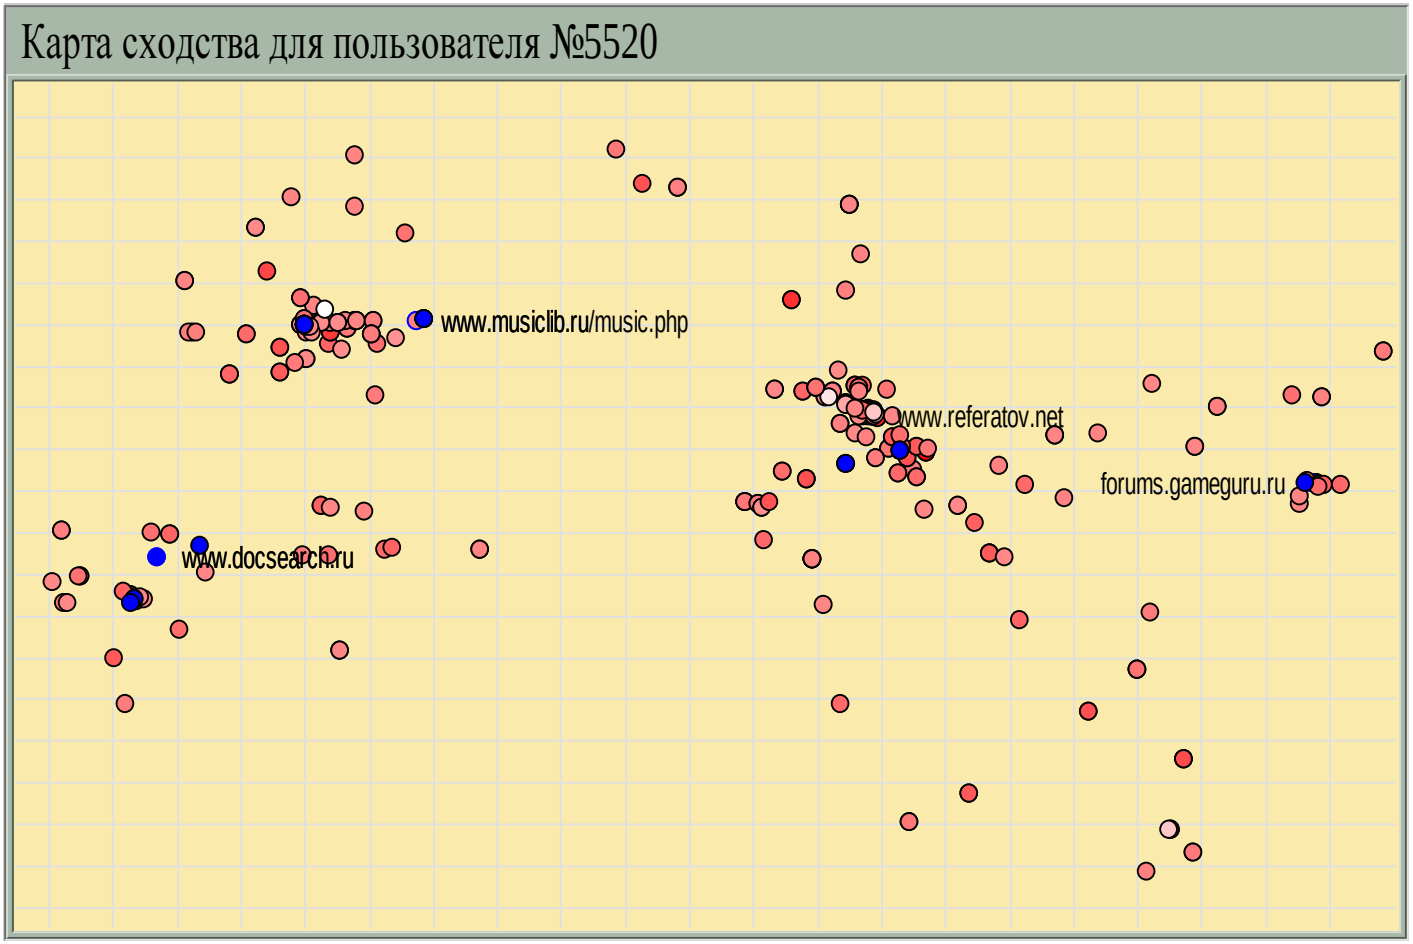

Резюме

Коллаборативная фильтрация — это набор методов для решения задач персонализации и **анализа клиентских сред**.

Простые методы *основаны на хранении исходных данных*.

Латентные модели, основанные на оценивании профилей клиентов и объектов, обладают рядом преимуществ:

- оценки сходства клиентов и объектов более адекватны;
- с профилями можно делать многое:
  — содержательно интерпретировать;
  — частично оценивать по априорным данным;
  — обновлять динамически по мере поступления данных;
  — сравнивать целиком или по фрагментам;
- снимается проблема «холодного старта»;
- резко сокращается объём хранимых данных;

Конец

1. Спасибо за внимание!
2. Вопросы?
3. Ссылки: вики www.MachineLearning.ru
   - «Участник:Vokov»
   - «Анализ клиентских сред»
   - «Коллаборативная фильтрация»
4. Ещё ссылки (хорошие подборки статей по CF):
   - jamesthornton.com/cf
   - www.adastral.ucl.ac.uk/∼junwang/CollaborativeFiltering.html