

---

# Методы и алгоритмы метрического анализа клиентских сред

В. А. Лексин

Заочная аспирантура МФТИ, III год

Научный руководитель К. В. Воронцов

## Научные результаты, полученные за предыдущие годы




Рис.: Этапы исследований

## Научные результаты, полученные за 2005-2007гг

- ▶ Исследованы методы прямого вычисления метрик в системах взаимодействующих объектов.
- ▶ Предложен вероятностный алгоритм, основанный на гипотезе о независимости посещения пользователем различных ресурсов (точный тест Фишера).
- ▶ Использована технология многомерного шкалирования и построения карт сходства для визуальной оценки кластерных свойств полученных метрик.
- ▶ Проведено исследование в рамках научной стипендии Яндекс: анализ лога поисковых запросов Яндекса методами АКС.
- ▶ Построены различные функционалы качества полученных метрик, основанные на частичной экспертной разметке ресурсов.

## Научные результаты, полученные за 2007-2009гг

- ▶ Предложен двухступенчатый итерационный алгоритм, позволяющий оценивать скрытые профили малой размерности, а затем получать из этих профилей метрики на множествах пользователей и ресурсов.
- ▶ Произведено сравнение метода с прямым вычислением метрики, а также с другими известными подходами в коллаборативной фильтрации. Был выявлен ряд преимуществ рассматриваемого метода.
- ▶ Исследованы свойства переобучения алгоритма при слишком большом количестве итераций в EM-алгоритме.
- ▶ Предложена технология генерации модельных данных для оценки качества и настройки параметров алгоритма.

## Научные результаты, полученные за последний год (2009-2010)

- ▶ Подключены данные о продажах товаров в крупной мебельной компании и данные форума.
- ▶ Исследованы алгоритмы построения **иерархических профилей**. Предложен **критерий достаточности** наблюдений для определения компонент профилей (публикация в сборнике трудов МФТИ).
- ▶ Теоретически и экспериментально проверена взаимосвязь алгоритма с методом градиентного спуска. Получена **оценка скорости сходимости** EM-итераций (осталось несколько открытых вопросов).
- ▶ Теоретически доказана взаимосвязь итерационного процесса максимизации правдоподобия в pLSA с минимизацией дивергенции Кульбака-Лейблера, для которой уже доказана **гарантированная сходимость к локальному экстремуму** (осталось несколько открытых вопросов).
- ▶ Экспериментально изучены свойства влияния начального приближения профилей на итоговый результат.

## Публикации 2005-2007

2007

- ▶ Оценивание сходства пользователей и ресурсов путем выявления скрытых тематических профилей. Тезисы для конференции МФТИ.
- ▶ Анализ клиентских сред: выявление скрытых профилей и оценивание сходства клиентов и ресурсов. Воронцов К. В., Лексин В. А. Тезисы доклада на конференции ММРО-13.
- ▶ Технология персонализации на основе выявления тематических профилей пользователей и ресурсов Интернет. Лексин В. А. Диплом магистра.

2006

- ▶ Персонализация контента на основе оценок сходства пользователей и ресурсов сети интернет. Тезисы конференции МФТИ.
- ▶ Система имитационного моделирования транспортной сети аэропорта AirForS. Чехович Ю. В., Ефимов А. Н., Лексин В. А., Романов М. Ю., Рудева А. В., Громов С. А., Яминов Р. И. Научно-теоретический журнал «Искусственный интеллект» №.2'2006.
- ▶ Выявление и визуализация метрических структур на множествах пользователей и ресурсов Интернет. К. В. Воронцов, К. В. Рудаков, В. А. Лексин, А. Н. Ефимов. Научно-теоретический журнал «Искусственный интеллект» №.2'2006.

2005

- ▶ Методы выявления взаимосогласованных структур сходства в системах взаимодействующих объектов. Лексин В. А. Диплом бакалавра.

## Публикации 2008-2009

2009

- ▶ Критерии ветвления в иерархическом вероятностном латентном семантическом анализе. В. А. Лексин. Сборник трудов МФТИ.
- ▶ **Symmetrization and overfitting in probabilistic latent semantic analysis. Pattern Recognition and Image Analysis. 2009. Volume 19. Number 4. December 2009. Pp. 565-574.**
- ▶ Двухступенчатые модели и проблема переобучения в латентном семантическом анализе. В. А. Лексин.

2008

- ▶ The overfitting in probabilistic latent semantic models. ROAI.
- ▶ Переобучение в вероятностных латентных семантических моделях. Лексин В. А., Воронцов К. В. Тезисы доклада на конференции РОАИ-2008.

## Выступления на конференциях и семинарах

- ▶ *3 ноября 2009.* Иерархический вероятностный латентный семантический анализ. Семинар, ВЦ РАН.
- ▶ *14 мая 2009.* Двухступенчатые модели и проблема переобучения в латентном семантическом анализе. Семинар, ВЦ РАН.
- ▶ *17 сентября 2008.* The overfitting in probabilistic latent semantic models. ROAI, Н.Новгород, стендовый доклад.
- ▶ *20 мая 2008.* Сходство пользователей и ресурсов. Выявления скрытых тематических профилей. Семинар, ВЦ РАН.
- ▶ *24 ноября 2007.* Оценивание сходства пользователей и ресурсов путем выявления скрытых тематических профилей. Конференция МФТИ, г. Долгопрудный, Моск. обл.
- ▶ *2 октября 2007.* Анализ клиентских сред: выявление скрытых профилей и оценивание сходства клиентов и ресурсов. ММРО-13, г. Зеленогорск Ленинградской обл.
- ▶ *25 ноября 2006.* Интеллектуальный анализ данных о сходстве пользователей и ресурсов Интернет. Конференция МФТИ, г. Долгопрудный, Моск. обл.
- ▶ *7 июня 2006.* Анализ данных о поведении пользователей сети Интернет. ИОИ-2006, г. Алушта, Крым, Украина.
- ▶ *22 ноября 2005.* Выявление и визуализация метрических структур на множествах пользователей и ресурсов Интернет. ММРО-12, г. Звенигород, Моск. обл.

## План дальнейших исследований. Экспериментальная работа

- ▶ Участие в создании проекта "*Полигон алгоритмов коллаборативной фильтрации*".
- ▶ Исследование и разработка функционалов качества алгоритмов коллаборативной фильтрации для последующего применения их в полигоне.
- ▶ Тестирование алгоритма на различных исходных данных.  
Сравнение алгоритмов.

## План дальнейших исследований. Теоретическая работа

- ▶ Алгоритмы построения иерархических профилей и алгоритмы динамического обновления профилей при пополнении исходных данных.
- ▶ Дальнейшая разработка критериев достаточности наблюдений для определения компонент профилей.
- ▶ Дальнейшее теоретическое исследование сходимости и переобучения алгоритма.
- ▶ Исследование и оптимизация методов задания начального приближения профилей. Учет априорной информации.
- ▶ Обобщение алгоритма на случай дискретных рейтингов.
- ▶ Изучение кластерных свойств алгоритма.
- ▶ ***Написание статьи (текст в процессе подготовки).***
- ▶ ***Защита диссертации.***