

# Тематическое моделирование структуры расходов клиентов банка

Воронцов Константин Вячеславович  
(ФИЦ ИУ РАН • МФТИ • МГУ • ВШЭ • Яндекс)

Айсина Роза Мунеровна  
(ВМК МГУ)

The logo for Data Science Day features a green background with a network of white dots and lines. The text "Data Science" is positioned above "Day".

Data Science  
Day

Москва • 12 ноября 2016

Вероятностное тематическое моделирование обычно применяется для информационного поиска, классификации и анализа документов в больших текстовых коллекциях.

В его основе лежат весьма универсальные математические методы — матричные разложения и регуляризация некорректно поставленных задач.

Поэтому спектр применений тематического моделирования может выходить далеко за рамки текстовой аналитики. Мы применили его для выявления латентных паттернов в структуре потребления клиентов Сбербанка.

- 1 Философия и мотивации тематического моделирования**
  - Что такое «тема» в текстовой коллекции
  - Разведочный информационный поиск
  - Требования к тематическим моделям
- 2 Теория и методы тематического моделирования**
  - Математическая постановка задачи
  - Теория аддитивной регуляризации (ARTM)
  - Некоторые приложения тематического моделирования
- 3 Тематическое моделирование транзакционных данных**
  - Исходные данные: Sberbank Data Science Contest
  - Интерпретация тематической модели
  - Темы как типы экономического поведения

## Что такое «тема» в коллекции текстовых документов?

Неформально,

- *тема* — семантически однородный кластер текстов
- *тема* — специальная терминология предметной области
- *тема* — набор часто совместно встречающихся терминов
- тем много меньше, чем терминов и чем документов

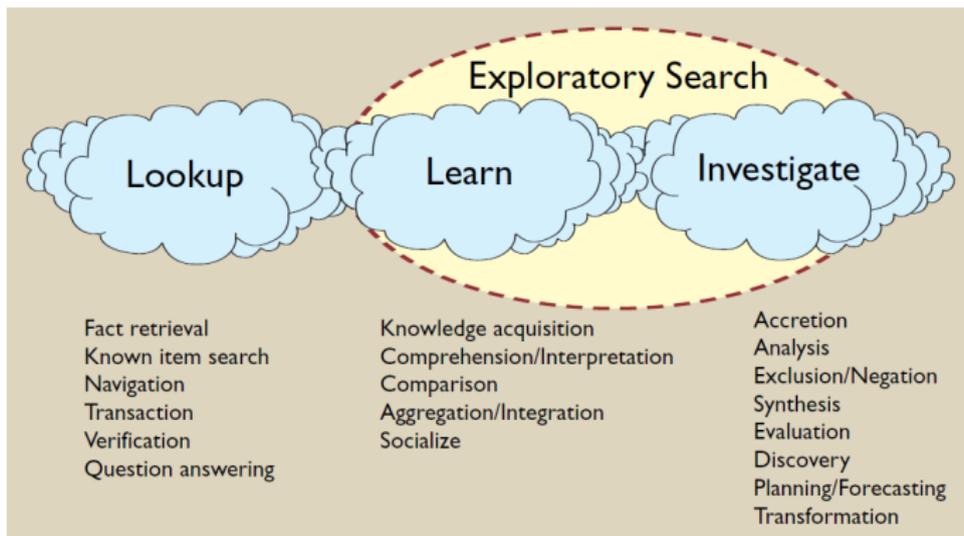
Более формально,

- *тема* — условное распределение на множестве терминов,  
 $p(w|t)$  — вероятность (частота) термина  $w$  в теме  $t$ ;
- *тематика* документа — условное распределение  
 $p(t|d)$  — вероятность (частота) темы  $t$  в документе  $d$ .

*Тематическая модель* оценивает вероятности  $p(w|t)$  и  $p(t|d)$  по наблюдаемым частотам  $p(w|d)$  слов  $w$  в документах  $d$ .

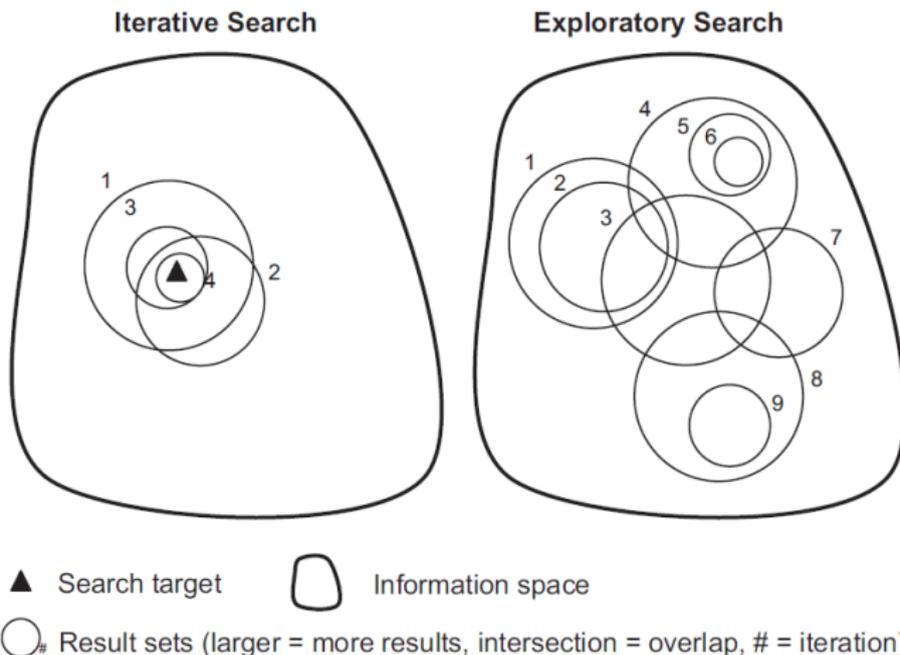
## Концепция разведочного поиска (exploratory search)

- пользователь может не знать ключевых терминов
- пользователя может интересовать множество ответов



Gary Marchionini. Exploratory Search: from finding to understanding. 2006.

## От итераций «query-browse-refine» к разведочному поиску



*R.W.White, R.A.Roth. Exploratory Search: beyond the Query-Response paradigm. San Rafael, CA: Morgan and Claypool, 2009.*

## Возможный сценарий разведочного поиска

### Поисковый запрос:

- документ любой длины или даже коллекция документов

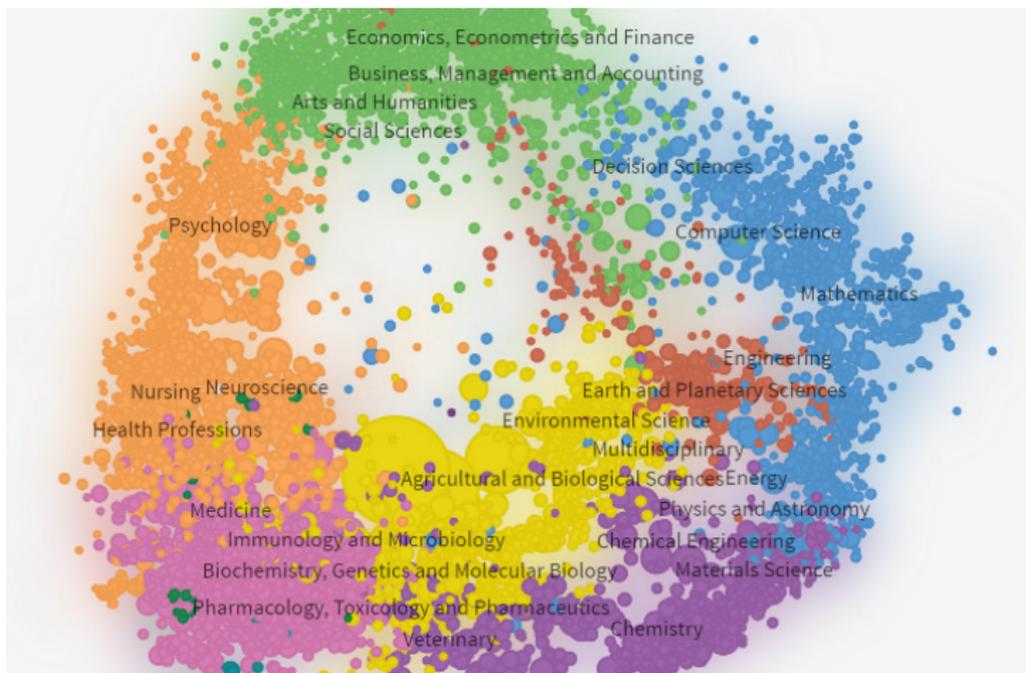
### Цели поиска:

- к каким темам относится мой запрос?
- что ещё известно по этим темам?
- какова тематическая структура этой предметной области?
- какие области являются смежными?
- что ещё есть понятного, обзорного, важного, свежего?

### Сценарий поиска:

- 1 имея любой текст под рукой, в любом приложении,
- 2 хотим получить картину содержащихся в нём тем-подтем,
- 3 и «дорожную карту» предметной области в целом

## Пример карты науки



<http://onlinelibrary.wiley.com/browse/subjects>





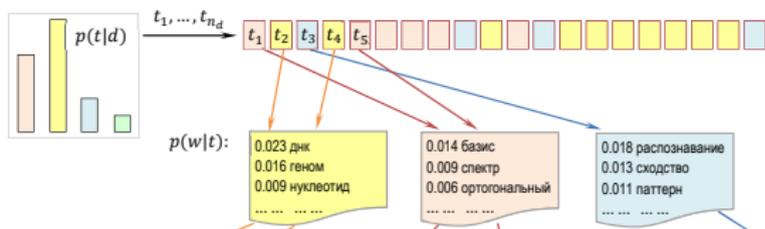
## Тематическая модель для разведочного поиска должна быть...

- 1 **Интерпретируемая:** каждая тема понятна людям
- 2 **Иерархическая:** систематизация областей знания
- 3 **Темпоральная:** обнаружение и прослеживание тем
- 4 **Мультиграммная:** выделение тематичных словосочетаний
- 5 **Мультимодальная:** авторы, связи, тэги, пользователи,...
- 6 **Мультиязычная:** кросс- и много-языковой поиск
- 7 **Разреженная:** сокращение поискового индекса
- 8 **Сегментирующая:** выделение тем внутри документа
- 9 **Обучаемая:** учёт обратной связи с пользователями
- 10 **Создающая и именующая темы** автоматически
- 11 **Онлайновая:** обрабатывающая коллекцию за 1 проход
- 12 **Параллельная, распределённая:** для больших коллекций

## Вероятностная модель порождения текстовой коллекции

объясняет появление терминов  $w$  в документах  $d$  темами  $t$ :

$$p(w|d) = \sum_t p(w|t)p(t|d), \quad d \in D$$



$w_1, \dots, w_{n_d}$ :

Разработан спектрально-аналитический подход к выявлению размытых протяженных повторов в геномных последовательностях. Метод основан на разномасштабном оценивании сходства нуклеотидных последовательностей в пространстве коэффициентов разложения фрагментов кривых GC- и GA-содержания по классическим ортогональным базисам. Найлены условия оптимальной аппроксимации, обеспечивающие автоматическое распознавание повторов различных видов (прямых и инвертированных, а также тандемных) на спектральной матрице сходства. Метод одинаково хорошо работает на разных масштабах данных. Он позволяет выявлять следы сегментных дупликаций и мегасателлитные участки в геноме, районы синтении при сравнении пары геномов. Его можно использовать для детального изучения фрагментов хромосом (поиска размытых участков с умеренной длиной повторяющегося паттерна).

## Обратная задача — восстановление $p(w|t)$ и $p(t|d)$ по коллекции

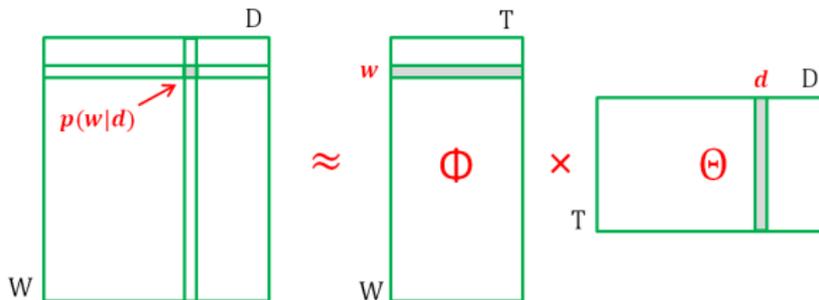
**Дано:** коллекция текстовых документов

- $n_{dw}$  — частоты терминов в документах,  $p(w|d) = \frac{n_{dw}}{n_d}$

**Найти:** параметры тематической модели  $p(w|d) = \sum_{t \in T} \phi_{wt} \theta_{td}$

- $\phi_{wt} = p(w|t)$  — вероятности терминов  $w$  в каждой теме  $t$
- $\theta_{td} = p(t|d)$  — вероятности тем  $t$  в каждом документе  $d$

Это задача стохастического матричного разложения:



## Задачи, некорректно поставленные по Адамару

Задача корректно поставлена, если:

- её решение существует,
- её решение единственно,
- её решение устойчиво (непрерывно зависит от данных в некоторой разумной топологии).



Жак Саломон Адамар  
(1865–1963),

Задача стохастического матричного разложения является *некорректно поставленной* — её решение не единственно:

$$\Phi\Theta = (\Phi S)(S^{-1}\Theta) = \Phi'\Theta'$$

для невырожденных  $S_{T \times T}$  таких, что  $\Phi', \Theta'$  — стохастические.

**Регуляризация** — дополнительные ограничения на  $\Phi, \Theta$ .

## Основные вехи развития тематического моделирования

- PLSA (1999) решает нерегуляризованную задачу
- LDA (2003) регуляризатор Дирихле, самая известная модель
- ATM (2004) авторы документов
- TOT (2006) метки времени документов
- HDP (2006) определение числа тем
- TNG (2007) группирование слов в мультиграммы
- CTM (2007) корреляции между темами
- NetPLSA (2008) граф связей между документами
- ML-LDA (2009) многоязычные параллельные тексты
- ssLDA (2012) частичное обучение
- Dependency-LDA (2012) категоризация документов
- mLDA (2013) метаданные с тремя и более модальностями
- BitermTM (2013) анализ коротких документов
- WNTM (2014) локальные контексты слов

## Байесовская регуляризация — доминирующий подход в ВТМ

*Байесовский вывод* — основа LDA и последующих моделей:

$$\text{Prior}(\Phi, \Theta) + \text{Data} \rightarrow \text{Posterior}(\Phi, \Theta).$$

**Проблемы:**

- Нам нужны лишь значения  $\Phi, \Theta$ , а не их распределения
- Используемые  $\text{Prior}(\Phi, \Theta)$  удобны для математических выкладок, но лингвистически не обоснованы
- Байесовский вывод уникален для каждой модели
- Технически трудно комбинировать модели
- Невозможно реализовать тысячи моделей в одном коде
- Плоская нотация не способствует пониманию моделей

---

*Rob Zinkov. Stop using Plate Notation.*

<http://zinkov.com/posts/2013-07-28-stop-using-plates>

# Байесовское обучение — доминирующий подход в ВТМ

The collage features several mathematical expressions and graphical models:

- Formulas:**
  - $p(\Theta|\alpha) = \prod_{d=1}^D p(\theta_{d,\cdot}|\alpha) = \prod_{d=1}^D \prod_{k=1}^K \frac{\Gamma(\alpha_k)}{\Gamma(\alpha)} \prod_{i=1}^n \theta_{d,i}^{\alpha_k - 1}$
  - $p(Z|\Theta) = \prod_{d=1}^D \prod_{i=1}^n \theta_{d,i}^{\sum_{k=1}^K z_{d,i,k}}$
  - $p(Z|\alpha) = \int p(Z|\Theta)p(\Theta|\alpha)d\Theta$
  - $\Omega(d,k) = \sum_{i=1}^n \mathbb{1}[d_i = m \wedge z_{i,k} = 1]$
  - $p(Z,W|\alpha,\beta) = \int p(Z,W|\Theta,\beta)p(\Theta|\alpha)d\Theta$
  - $p(z_i = k | Z_{-i}, W_{-i})$
  - $p(z_i = k | Z_{-i}, W_{-i}, \alpha, \beta)$
- Graphical Models:**
  - Plate notation models for  $\theta_{d,i}$  and  $z_{d,i}$ .
  - Bayesian networks showing dependencies between  $\alpha$ ,  $\beta$ ,  $\theta$ ,  $z$ , and  $w$ .
  - A model with a note: "Parse trees grouped into M documents".
  - Complex plate notation models for hierarchical or multi-level topic modeling.

# ARTM — альтернатива байесовскому обучению

$$\left\{ \begin{array}{l} P_{tdw} = \text{norm}_t(\phi_{wt}\theta_{td}) \\ \phi_{wt} = \text{norm}_w\left(\sum_d n_{dw}P_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}}\right) \\ \theta_{td} = \text{norm}_t\left(\sum_w n_{dw}P_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}}\right) \end{array} \right.$$

Воронцов К. В. Аддитивная регуляризация тематических моделей коллекций текстовых документов. Доклады РАН. 2014.

## ARTM — Аддитивная Регуляризация Тематических Моделей

Максимизация log правдоподобия с регуляризатором  $R$ :

$$\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}; \quad R(\Phi, \Theta) = \sum_i \tau_i R_i(\Phi, \Theta)$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{cases} \text{E-шаг:} & p_{tdw} = \operatorname{norm}_{t \in T}(\phi_{wt} \theta_{td}) \\ \text{M-шаг:} & \begin{cases} \phi_{wt} = \operatorname{norm}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right) \\ \theta_{td} = \operatorname{norm}_{t \in T} \left( \sum_{w \in W} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{cases} \end{cases}$$

Модель PLSA:  $R(\Phi, \Theta) = 0$

Модель LDA:  $R(\Phi, \Theta) = \sum_{t,w} \beta_w \ln \phi_{wt} + \sum_{d,t} \alpha_t \ln \theta_{td}$



## Обобщение ARTM на мультимодальные задачи

$W^m$  — словарь токенов  $m$ -й модальности,  $m \in M$

$W = W^1 \sqcup \dots \sqcup W^M$  — объединённый словарь всех модальностей

Максимизация суммы  $\log$  правдоподобий с регуляризацией:

$$\sum_{m \in M} \lambda_m \sum_{d \in D} \sum_{w \in W^m} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{array}{l} \text{E-шаг:} \\ \text{M-шаг:} \end{array} \left\{ \begin{array}{l} p_{tdw} = \mathop{\text{norm}}_{t \in T} (\phi_{wt} \theta_{td}) \\ \phi_{wt} = \mathop{\text{norm}}_{w \in W^m} \left( \sum_{d \in D} \lambda_{m(w)} n_{dw} p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in d} \lambda_{m(w)} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{array} \right.$$

## BigARTM: библиотека тематического моделирования

### Ключевые возможности:

- Онлайн-параллельный мультимодальный ARTM
- Большие данные: коллекция не хранится в памяти
- Встроенная библиотека регуляризаторов и мер качества

### Сообщество:

- Открытый код <https://github.com/bigartm>  
(discussion group, issue tracker, pull requests)
- Документация <http://bigartm.org>



### Лицензия и среда разработки:

- Freely available for commercial usage (BSD 3-Clause license)
- Cross-platform — Windows, Linux, Mac OS X (32 bit, 64 bit)
- Programming APIs: command-line, C++, and Python

# BigARTM: унификация разработки тематических моделей

## Этапы моделирования

### Bayesian TM

### ARTM

	Bayesian TM	ARTM
	Анализ требований	Анализ требований
Формализация:	Вероятностная порождающая модель данных	Стандартные критерии   Свои критерии
Алгоритмизация:	Байесовский вывод для данной порождающей модели (VI, GS, EP)	Общий регуляризованный EM-алгоритм для любых моделей
Реализация:	Исследовательский код (Matlab, Python, R)	Промышленный код BigARTM (C++, Python API)
Оценивание:	Исследовательские метрики, исследовательский код	Стандартные метрики   Свои метрики
	Внедрение	Внедрение

-- нестандартизируемые этапы, уникальная разработка для каждой задачи

-- стандартизируемые этапы

# Разработка тематических моделей в среде IPython Notebook

<http://nbviewer.ipython.org/github/bigartm/bigartm-book/tree/master/>

## Коллекция:

Используем небольшую коллекцию 'kos', доступную в репозитории UCI  
<https://archive.ics.uci.edu/ml/machine-learning-databases/bag-of-words/>. Параметры коллекции следующие:

- 3430 документов;
- 6906 слов в словаре;
- 46714 слов в коллекции.

Для начала подключим все необходимые модули (убедитесь, что путь к Python API BigARTM находится в вашей переменной PATH):

```
In [1]: %matplotlib inline
import glob
import matplotlib.pyplot as plt
import artm
```

Прежде всего необходимо подготовить входные данные. BigARTM имеет собственный формат документов для обработки, называемый батчами. В библиотеке присутствуют средства по созданию батчей из файлов Bag-Of-Words в форматах UCI и Wowpal Wabbit (подробности можно найти в <http://docs.bigartm.org/en/latest/formats.html>).

В Python API, по аналогии с алгоритмами из scikit-learn, входные данные представлены одним классом BatchVectorizer. Объект этого класса принимает на вход батчи или файлы с Bag-Of-Words и подается на вход всем методам. В случае, если входные данные не являются батчами, он создаст их и сохранит на диск для последующего быстрого использования.

Итак, создадим объект BatchVectorizer:

```
In [2]: batch_vectorizer = None
if len(glob.glob('kos' + '/*.*.batch')) < 1:
    batch_vectorizer = artm.BatchVectorizer(data_path='', data_format='bow
_uci', collection_name='kos', target_folder='kos')
else:
    batch_vectorizer = artm.BatchVectorizer(data_path='kos', data_format='
batches')
```

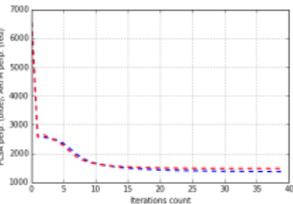
ARTM — это класс, представляющий собой Python API BigARTM, и позволяющий использовать практически все возможности библиотеки в стиле scikit-learn. Создадим две тематические модели для нашего эксперимента. Наиболее важным параметром модели является число тем. Опционально можно указать списки регуляризаторов и функционалов качества, которые следует использовать для данной модели. Если этого не сделать, то регуляризаторы и функционалы всегда можно добавить позднее. Обратите внимание, что каждая модель задаёт

Продолжим обучение моделей, инициализав 25 проходов по коллекции, после чего снова посмотрим на значения функционалов качества:

```
In [11]: model_plsa.fit_offline(batch_vectorizer=batch_vectorizer, num_collection_p
asses=25, num_document_passes=1)
model_artm.fit_offline(batch_vectorizer=batch_vectorizer, num_collection_p
asses=25, num_document_passes=1)
```

```
In [12]: print_measures(model_plsa, model_artm)
```

Sparsity Phi: 0.332 (FLSA) vs. 0.740 (ARTM)  
Sparsity Theta: 0.082 (FLSA) vs. 0.602 (ARTM)  
Kernel contrast: 0.530 (FLSA) vs. 0.548 (ARTM)  
Kernel purity: 0.396 (FLSA) vs. 0.531 (ARTM)  
Perplexity: 1362.804 (FLSA) vs. 1475.455 (ARTM)



Кроме того, для наглядности построим графики изменения разреженностей матриц по итерациям:

```
In [13]: plt.plot(xrange(model_plsa.num_phi_updates), model_plsa.score_tracker['Spa
rsityPhiScore'].value, 'b--',
              xrange(model_artm.num_phi_updates), model_artm.score_trac
ker['SparsityPhiScore'].value, 'r--', linewidth=2)
plt.xlabel('Iterations count')
plt.ylabel('FLSA Phi sp. (blue), ARTM Phi sp. (red)')
plt.grid(True)
plt.show()
```

```
plt.plot(xrange(model_plsa.num_phi_updates), model_plsa.score_tracker['Spa
rsityThetaScore'].value, 'b--',
         xrange(model_artm.num_phi_updates), model_artm.score_trac
ker['SparsityThetaScore'].value, 'r--', linewidth=2)
```

## Тесты производительности

- 3.7М статей английской Вики, 100К уникальных слов

	procs	train	inference	perplexity
BigARTM	1	35 min	72 sec	4000
Gensim.LdaModel	1	369 min	395 sec	4161
VowpalWabbit.LDA	1	73 min	120 sec	4108
BigARTM	4	9 min	20 sec	4061
Gensim.LdaMulticore	4	60 min	222 sec	4111
BigARTM	8	4.5 min	14 sec	4304
Gensim.LdaMulticore	8	57 min	224 sec	4455

- *procs* = число параллельных потоков
- *inference* = время тематизации 100К тестовых документов
- *perplexity* вычислена на тестовой выборке документов

## Мониторинг межнациональных отношений в соцсети

**Дано:** посты социальных сетей.

**Найти:** темы, связанные с межнациональными отношениями.

**Регуляризаторы:**

- частичное обучение тем по словарю этнонимов
- учёт модальностей геолокаций и времени
- повышение различности тем
- выделение фоновых тем общей лексики

---

*M. Apishev, S. Koltcov, O. Koltsova, S. Nikolenko, K. Vorontsov. Mining Ethnic Content Online with Additively Regularized Topic Models. Computación y Sistemas, 2016.*

## Тематизация новостных потоков для медиапланирования

**Дано:** новости от многих источников СМИ.

**Найти:** иерархию и динамику развития тем;  
оценки сходства тематических спектров новостных источников.

**Регуляризаторы:**

- связывание уровней иерархии
- учёт модальностей времени и источников
- повышение различности тем
- выделение фоновых тем общей лексики

## Сценарный анализ записей разговоров контакт-центра

**Дано:** текстовые записи разговоров контакт-центра.

**Найти:** тематическую сегментацию каждого разговора;  
отклонения от инструкций в работе операторов;  
автоматизировать переключения и подсказки оператору.

**Регуляризаторы:**

- частичное обучение тем по текстам инструкций
- определение границ тематических сегментов
- повышение различности тем
- выделение фоновых тем общей лексики

## Разведочный тематический поиск

**Дано:** тексты коллективного блога (Хабрахабр)

**Найти:** алгоритм ранжирования по тематической близости и оценить качество тематического поиска.

**Регуляризаторы:**

- разреживание  $p(t|d)$  для сокращения поискового индекса
- учёт модальностей авторов, комментаторов, тегов, хабов
- повышение различности тем
- выделение фоновых тем общей лексики

---

*А.О.Янина, К.В.Воронцов. Мультимодальные тематические модели для разведочного поиска в коллективном блоге. JMLDA, 2016.*

## Скрининговая диагностика по электрокардиограмме

**Дано:** дискретизированные ЭКГ-сигналы + диагнозы  
(данные о варибельности сердечного ритма, закодированные в символную последовательность)

**Найти:** темы — диагностические эталоны заболеваний;  
алгоритм оценивания риска болезни.

**Регуляризаторы:**

- учёт диагнозов в обучающей выборке
- повышение различности тем
- выделение фоновых тем

## Анализ данных о транзакциях клиентов банка

**Дано:**

$D$  — множество клиентов (15 000)

$W$  — категории = MCC-коды (Merchant Category Code) (328)

$n_{dw}$  — сумма транзакций клиента  $d$  по категории  $w$

**Найти:** темы — типы экономического поведения (потребления)

$\phi_{wt} = p(w|t)$  — структура потребления для темы  $t$

$\theta_{td} = p(t|d)$  — типы потребления клиента  $d$

**Регуляризаторы:**

- повышение различности тем
- разреживание  $p(t|d)$
- учёт модальностей времени, типа транзакции, терминала
- обучение прогнозов объёма трат по метрике  $\text{RMSLE}_1$

## Интерпретация тематической модели

Прогноз объёма трат клиента  $d$  по категории  $w$

$$n_{dw} = n_d \sum_{t \in T} p(w|t)p(t|d),$$

$n_d$  — объём клиента  $d$  по всем категориям или его прогноз.

**Проблема** несбалансированности клиентов по объёмам:  
приоритет получают «богатые» клиенты с наибольшими  $n_d$

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta}$$

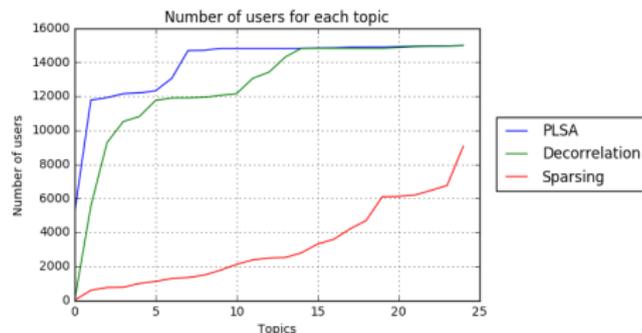
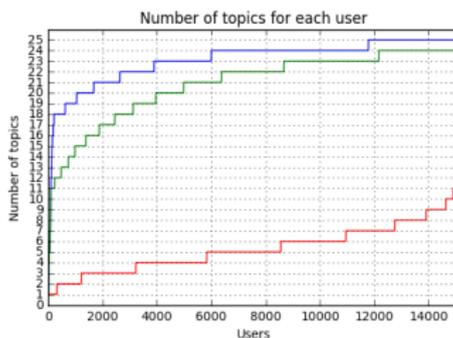
Два способа решения (первый сохраняет аддитивность объёмов):

$$\sum_{d \in D} \sum_{w \in d} \frac{1}{n_d} n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta};$$

$$\sum_{d \in D} \sum_{w \in d} \log n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta}$$

## Построение модели ARTM, 25 тем

- 30 итераций PLSA — без регуляризаторов
- 10 итераций — повышение различности тем
- 10 итераций — разреживание  $p(t|d)$



Декоррелирование  $\Phi$  и разреживание  $\Theta$  определяют минимальное число типов экономического поведения каждого клиента, достаточное для описания его расходов.

## Пользуюсь картой только чтобы снять наличные

- $\phi_{wt},\%$  МСС-код (категория расходов)
  - 72 Финансовые институты — снятие наличности вручную
  - 27 Финансовые институты — снятие наличности автоматически
  - 0.23 Денежные переводы MasterCard MoneySend
  - 0.1 Денежные переводы
  - 0.012 Финансовые институты — снятие наличности вручную
  - 0.0055 Легковой и грузовой транспорт: продажа, сервис, ремонт, запчасти, лизинг
  - 0.0027 Магазины игрушек

## Наличные + авто, спорт, компьютеры

- $\phi_{wt},\%$  МСС-код (категория расходов)
- 55 Финансовые институты — снятие наличности автоматически
  - 44 Денежные переводы
  - 0.111 Станции техобслуживания
  - 0.105 Автозапчасти и аксессуары
  - 0.094 Компьютерная сеть/информационные услуги
  - 0.043 Спортивная одежда, одежда для верховой езды и езды на мотоцикле
  - 0.024 Финансовые институты — снятие наличности вручную
  - 0.020 СТО общего назначения
  - 0.018 Горючее топливо — уголь, нефть, разжиженный бензин, дрова
  - 0.015 Магазины мужской и женской одежды
  - 0.015 Финансовые институты — снятие наличности вручную
  - 0.013 Магазины спорттоваров
  - 0.012 Садовые принадлежности (в том числе для ухода за газонами) в розницу
  - 0.011 Паркинги и гаражи
  - 0.011 Бакалейные магазины, супермаркеты
  - 0.010 Различные магазины одежды и аксессуаров

## Цивилизованный потребитель: разные магазины, связь, авто

- $\phi_{wt}, \%$  МСС-код (категория расходов)
- 27 Станции техобслуживания
  - 20 Различные продовольственные магазины, рынки, полуфабрикаты
  - 15 Звонки с использованием телефонов, считывающих магнитную ленту
  - 12 Финансовые институты — снятие наличности автоматически
  - 4.7 Горючее топливо — уголь, нефть, разжиженный бензин, дрова
  - 4.1 Универсальные магазины
  - 3.4 Автозапчасти и аксессуары
  - 1.4 Аптеки
  - 1.2 Магазины с продажей спиртных напитков на вынос
  - 1.1 Бакалейные магазины, супермаркеты
  - 0.57 Автошины
  - 0.37 Прямой маркетинг — торговля через каталог
  - 0.35 Товары для дома
  - 0.33 Универмаги
  - 0.32 Плавательные бассейны — распродажа
  - 0.21 Места общественного питания, рестораны

Всего 24 категории с  $\phi_{wt} > 0.1\%$ ; 61 категория с  $\phi_{wt} > 0.01\%$

## Продвинутые мамки

- $\phi_{wt}, \%$  МСС-код (категория расходов)
- 56 Бакалейные магазины, супермаркеты
  - 8.6 Финансовые институты — снятие наличности автоматически
  - 5.4 Аптеки
  - 4.0 Звонки с использованием телефонов, считывающих магнитную ленту
  - 2.2 Рестораны, закусочные
  - 1.8 Обувные магазины
  - 1.5 Различные продовольственные магазины — рынки, полуфабрикаты
  - 1.4 Магазины спорттоваров
  - 1.4 Детская одежда, включая одежду для самых маленьких
  - 1.3 Магазины игрушек
  - 1.3 Места общественного питания, рестораны
  - 1.1 Магазины мужской и женской одежды
  - 1.1 Магазины с продажей спиртных напитков на вынос
  - 1.1 Магазины косметики
  - 1.0 Садовые принадлежности в розницу
  - 0.73 Одежда для всей семьи

Всего 41 категория с  $\phi_{wt} > 0.1\%$ ; 95 категорий с  $\phi_{wt} > 0.01\%$

## Бизнес-леди: забыла про наличку — всё по карте

$\phi_{wt}, \%$  МСС-код (категория расходов)

- 12 Магазины мужской и женской одежды
- 7.3 Оборудование, мебель и бытовые принадлежности (кроме электрооборудования)
- 7.0 Места общественного питания, рестораны
- 5.6 Магазины по продаже часов, ювелирных изделий и изделий из серебра
- 5.3 Обувные магазины
- 4.7 Магазины косметики
- 4.6 Одежда для всей семьи
- 3.8 Универмаги
- 3.2 Готовая женская одежда
- 2.8 Практикующие врачи, медицинские услуги
- 1.8 Прямой маркетинг — торговля через каталог
- 1.5 Салоны красоты и парикмахерские
- 1.3 Детская одежда, включая одежду для самых маленьких
- 1.3 Аптеки
- 1.0 Изготовление и продажа меховых изделий
- 1.0 Центры здоровья

Всего 70 категорий с  $\phi_{wt} > 0.1\%$ ; 134 категории с  $\phi_{wt} > 0.01\%$

## Продвинутый активный потребитель всего, и по карте

$\phi_{wt}, \%$  МСС-код (категория расходов)

20 Финансовые институты — снятие наличности вручную

15 Универсальные магазины

13 Туристические агентства и организаторы экскурсий

11 Автозапчасти и аксессуары

8.8 Коммунальные услуги — электричество, газ, санитария, вода

4.2 Веломагазины — продажа и обслуживание

3.7 СТО общего назначения

0.9 Услуги курьера — по воздуху и на земле, агентство по отправке грузов

0.8 Рекламные услуги

0.7 Компьютеры, периферийное компьютерное оборудование, программное об

0.5 Образовательные услуги

0.4 Бакалейные магазины, супермаркеты

0.4 Практикующие врачи, медицинские услуги

0.3 Продажа мотоциклов

0.3 Оборудование, мебель и бытовые принадлежности (кроме электрооборудов

0.2 Автошины

Всего 35 категорий с  $\phi_{wt} > 0.1\%$ ; 93 категории с  $\phi_{wt} > 0.01\%$

## Бизнес-класс: авиа, отели, казино, рестораны, ценные бумаги

- $\phi_{wt}, \%$  МСС-код (категория расходов)
- 28 Авиа линии, авиакомпании
  - 19 Финансовые институты — торговля и услуги
  - 9.5 Отели, мотели, базы отдыха, сервисы бронирования
  - 8.6 Транзакции по азартным играм (плюс)
  - 5.2 Финансовые институты — торговля и услуги
  - 3.2 Места общественного питания, рестораны
  - 3.1 Не-финансовые институты: ин.валюта, переводы, дорожн.чеки, квази-кэш
  - 2.2 Пассажирские железнодорожные перевозки
  - 1.7 Бизнес-сервис
  - 1.4 Жилье — отели, мотели, курорты
  - 1.3 Галереи/учреждения видеоигр
  - 1.3 Транзакции по азартным играм (минус)
  - 0.6 Ценные бумаги: брокеры/дилеры
  - 0.5 Туристические агентства и организаторы экскурсий
  - 0.3 Лимузины и такси
  - 0.3 Беспшлинные магазины Duty Free

Всего 35 категорий с  $\phi_{wt} > 0.1\%$ ; 93 категории с  $\phi_{wt} > 0.01\%$

## Провинциальный малый бизнес

$\phi_{wt}, \%$  МСС-код (категория расходов)

- 27 Финансовые институты — снятие наличности автоматически
- 8.5 Лесо- и строительный материал
- 8.4 Бытовое оборудование
- 6.6 Плавательные бассейны — распродажа
- 5.5 Продажа электронного оборудования
- 4.1 Бакалейные магазины, супермаркеты
- 3.3 Универсальные магазины
- 3.0 Садовые принадлежности в розницу
- 2.6 Телекоммуникационное оборудование, включая продажу телефонов
- 2.4 Легковой и грузовой транспорт: продажа, сервис, ремонт, запчасти, лизинг
- 2.2 Товары для дома
- 2.1 Пассажирские железнодорожные перевозки
- 1.5 Оборудование, мебель и бытовые принадлежности (кроме электрооборудования)
- 1.3 Скобяные товары в розницу
- 1.2 Магазины спорттоваров
- 1.1 Аптеки

Всего 54 категории с  $\phi_{wt} > 0.1\%$ ; 104 категории с  $\phi_{wt} > 0.01\%$

- Когда нужна тематическая модель, все берут LDA, который может давать неустойчивые результаты, и пользуются пост-обработкой тем, найденных LDA
- ARTM позволяет оптимизировать темы под задачу, строить модели с заданными свойствами, комбинируя различные критерии и источники данных
- Новое применение тематического моделирования — анализ транзакционных данных банка



<http://bigartm.org>

Join BigARTM community!

-  *Воронцов К. В.* Аддитивная регуляризация тематических моделей коллекций текстовых документов. Доклады РАН. 2014.
-  *K.Vorontsov, A.Potapenko.* Tutorial on probabilistic topic modeling: Additive regularization for stochastic matrix factorization. AIST 2014.
-  *K.Vorontsov, A.Potapenko.* Additive regularization of topic models. Machine Learning, 2015.
-  *K.Vorontsov, O.Frei, M.Apishev, P.Romov, M.Suvorova, A.Yanina.* Non-bayesian additive regularization for multimodal topic modeling of large collections. 2015.
-  *K.Vorontsov, A.Potapenko, A.Plavin.* Additive regularization of topic models for topic selection and sparse factorization. SLDS 2015.
-  *O.Frei, M.Apishev.* Parallel non-blocking deterministic algorithm for online topic modeling. AIST 2016. (в печати)
-  *M.Apishev, S.Koltcov, O.Koltsova, S.Nikolenko, K.Vorontsov.* Additive regularization for topic modeling in sociological studies of user-generated text content. MICAI 2016. (в печати)
-  *А.О.Янина, К.В.Воронцов.* Мультимодальные тематические модели для разведочного поиска в коллективном блоге. ИОИ 2016. (в печати)