

# Матричные разложения в задачах семантического анализа текстов

Воронцов Константин Вячеславович  
(ВЦ РАН ФИЦ ИУ РАН • МФТИ)

Семинар отдела  
«Математическое моделирование экономических систем»  
ВЦ РАН ФИЦ ИУ РАН  
26 октября 2016

- 1 Задачи семантического анализа текстов**
  - Вероятностное тематическое моделирование
  - Простые тематические модели PLSA и LDA
  - Некорректность по Адамару
- 2 Задачи математического программирования**
  - Аддитивная регуляризация тематических моделей
  - Мультимодальные и гиперграфовые обобщения
  - Тематические модели последовательного текста
- 3 Реализация, эксперименты, приложения**
  - Программная реализация
  - Эксперименты
  - Приложения

## Что такое «тема» в коллекциях 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  $d$ .

## Вероятностная порождающая модель

### Основные предположения:

- каждый термин  $w \in W$  в документе  $d \in D$  имеет тему  $t \in T$
- $D \times W \times T$  — дискретное вероятностное пространство
- коллекция — это i.i.d. выборка  $(d_i, w_i, t_i)_{i=1}^n \sim p(d, w, t)$
- $d_i, w_i$  — наблюдаемые, темы  $t_i$  — скрытые
- гипотеза условной независимости:  $p(w|d, t) = p(w|t)$

### Вероятностная модель порождения документа $d$ :

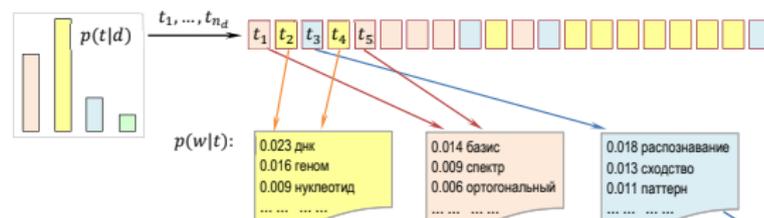
$$p(w|d) = \sum_{t \in T} p(w|t) p(t|d)$$

- $\phi_{wt} \equiv p(w|t)$  — распределение терминов в темах  $t \in T$ ;
- $\theta_{td} \equiv p(t|d)$  — распределение тем в документах  $d \in D$ .

## Прямая задача — порождение коллекции по $p(w|t)$ и $p(t|d)$

Вероятностная тематическая модель коллекции документов  $D$  описывает 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. Найдены 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:  $W$  — словарь терминов

$D$  — коллекция текстовых документов  $d = \{w_1 \dots w_{n_d}\}$

$n_{dw}$  = сколько раз термин  $w$  встречается в документе  $d$

Найти: параметры модели  $p(w|d) = \sum_t \phi_{wt} \theta_{td}$  при ограничениях

$$\phi_{wt} \geq 0, \sum_w \phi_{wt} = 1, \quad \theta_{td} \geq 0, \sum_t \theta_{td} = 1;$$

$\phi_{wt} = p(w|t)$  — вероятности терминов  $w$  в теме  $t$ ,

$\theta_{td} = p(t|d)$  — вероятности тем  $t$  в документе  $d$ .

Это задача *стохастического матричного разложения*.

Задача некорректно поставлена — её решение не единственно:

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

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

## PLSA — Probabilistic Latent Semantic Analysis [Hofmann, 1999]

Задача максимизации логарифма правдоподобия:

$$\mathcal{L}(\Phi, \Theta) = \sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений со вспомогательными переменными  $p_{tdw} = p(t|d, w)$ :

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

где  $\operatorname{norm}_{t \in T} x_t = \frac{\max\{x_t, 0\}}{\sum_{s \in T} \max\{x_s, 0\}}$  — операция нормировки вектора.

## LDA — Latent Dirichlet Allocation [Blei, Ng, Jordan, 2003]

Максимизация апостериорной вероятности (Dirichlet prior):

$$\underbrace{\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td}}_{\text{ln правдоподобия } \mathcal{L}(\Phi, \Theta)} + \underbrace{\sum_{t,w} (\beta_w - 1) \ln \phi_{wt} + \sum_{d,t} (\alpha_t - 1) \ln \theta_{td}}_{\text{регуляризатор с параметрами } \beta_w > 0, \alpha_t > 0} \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений

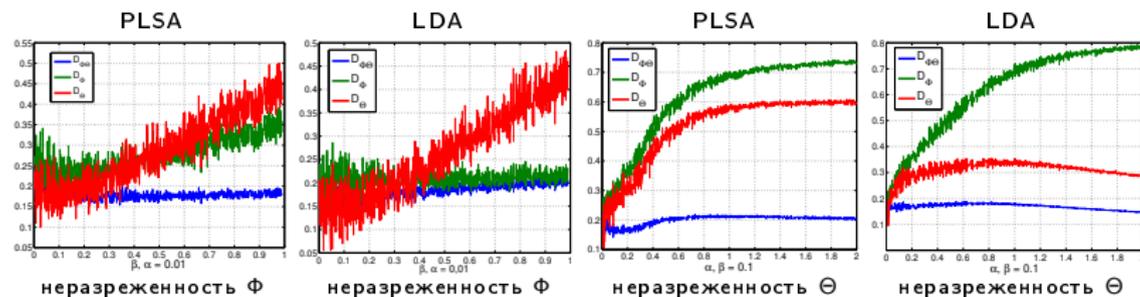
$$\begin{cases} \text{E-шаг:} & p_{tdw} = \mathop{\text{norm}}_{t \in T}(\phi_{wt} \theta_{td}) \\ \text{M-шаг:} & \begin{cases} \phi_{wt} = \mathop{\text{norm}}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} + \beta_w - 1 \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in W} n_{dw} p_{tdw} + \alpha_t - 1 \right) \end{cases} \end{cases}$$

## Задача тематического моделирования некорректно поставлена

Неединственность стохастического матричного разложения:

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

Эксперимент. Произведение  $\Phi\Theta$  восстанавливается устойчиво, матрица  $\Phi$  и матрица  $\Theta$  — только когда сильно разрежены:



Вывод 1: нужны дополнительные ограничения на модель.

Вывод 2: регуляризатор Дирихле в LDA — слишком слабый.

## ARTM — Аддитивная регуляризация тематических моделей

Максимизация  $\log$  правдоподобия с регуляризатором  $R$ :

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

EM-алгоритм: метод простой итерации для системы уравнений

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

Воронцов К. В. Аддитивная регуляризация тематических моделей коллекций текстовых документов. Доклады РАН, 2014. Т. 455., № 3. 268–271.

## Комбинирование регуляризованных тематических моделей

Максимизация  $\log$  правдоподобия с  $n$  регуляризаторами  $R_i$ :

$$\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} + \sum_{i=1}^n \tau_i R_i(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

где  $\tau_i$  — коэффициенты регуляризации.

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{cases} \text{E-шаг:} & p_{tdw} = \mathop{\text{norm}}_{t \in T}(\phi_{wt} \theta_{td}) \\ \text{M-шаг:} & \begin{cases} \phi_{wt} = \mathop{\text{norm}}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} + \phi_{wt} \sum_{i=1}^n \tau_i \frac{\partial R_i}{\partial \phi_{wt}} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in W} n_{dw} p_{tdw} + \theta_{td} \sum_{i=1}^n \tau_i \frac{\partial R_i}{\partial \theta_{td}} \right) \end{cases} \end{cases}$$

## Примеры регуляризаторов

- 1 декоррелирование тем как столбцов  $\Phi$ :

$$R(\Phi) = -\frac{\tau}{2} \sum_{t \in S} \sum_{s \in S \setminus t} \sum_{w \in W} \phi_{wt} \phi_{ws} \rightarrow \max$$

- 2 учёт *битермов* — пар слов, близко стоящих  $n_{uw}$  раз:

$$R(\Phi) = \tau \sum_{u, w \in W} n_{uw} \ln \sum_{t \in T} n_t \phi_{ut} \phi_{wt} \rightarrow \max$$

- 3 удаление неинформативных тем:

$$R(\Theta) = -\tau \sum_{t \in S} \ln p(t) \rightarrow \max, \quad p(t) = \sum_{d \in D} \theta_{td} p(d)$$



## Мультимодальная ARTM [Vorontsov et al, 2015]

$W^m$  — 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

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

## Порождающая модальность и трёх-матричные разложения

### Основные предположения:

- $C$  — порождающая модальность (категории, авторы, ...)
- $D \times W \times T \times C$  — дискретное вероятностное пространство
- коллекция — i.i.d. выборка  $(d_i, w_i, t_i, c_i)_{i=1}^n \sim p(d, w, t, c)$
- два предположения об условной независимости:  
 $p(w|d, t) = p(w|t)$ ,  $p(t|c, d) = p(t|c)$

### Вероятностная модель порождения документа $d$ :

$$p(w|d) = \sum_{t \in T} p(w|t) \sum_{c \in C} p(t|c) p(c|d) = \sum_{t \in T} \phi_{wt} \sum_{c \in C} \psi_{tc} \pi_{cd}$$

- $\phi_{wt} \equiv p(w|t)$  — распределение терминов в темах
- $\psi_{tc} \equiv p(t|c)$  — распределение тем в категориях
- $\pi_{cd} \equiv p(c|d)$  — распределение категорий в документах

## ARTM для трёх-матричных разложений $\Phi\Psi\Pi$

Максимизация  $\log$  правдоподобия с регуляризатором  $R$ :

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \ln \sum_{t \in T} \sum_{c \in C} \phi_{wt} \psi_{tc} \pi_{cd} + R(\Phi, \Psi, \Pi) \rightarrow \max_{\Phi, \Psi, \Pi};$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\left\{ \begin{array}{l} \text{E-шаг:} \\ \text{M-шаг:} \end{array} \right. \left\{ \begin{array}{l} p_{tcdw} \equiv p(t, c|d, w) = \operatorname{norm}_{(t,c) \in T \times C} (\phi_{wt} \psi_{tc} \pi_{cd}); \\ \phi_{wt} = \operatorname{norm}_{w \in W^m} \left( n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right); \quad n_{wt} = \sum_{d,c} n_{dw} p_{tcdw} \\ \psi_{tc} = \operatorname{norm}_{t \in T} \left( n_{tc} + \psi_{tc} \frac{\partial R}{\partial \psi_{tc}} \right); \quad n_{tc} = \sum_{d,w} n_{dw} p_{tcdw} \\ \pi_{cd} = \operatorname{norm}_{c \in C} \left( n_{cd} + \pi_{cd} \frac{\partial R}{\partial \pi_{cd}} \right); \quad n_{cd} = \sum_{w,t} n_{dw} p_{tcdw} \end{array} \right.$$

## Гиперграфовые модели для транзакционных данных

Выборка может содержать не только пары  $(d, w)$ , но также тройки,  $\dots$ ,  $n$ -ки элементов разных модальностей.

**Примеры:**

- **Данные социальной сети:**  
 $(d, u, w)$  — в блоге  $d$  пользователь  $u$  записал слово  $w$
- **Данные сети интернет-рекламы:**  
 $(u, d, b)$  — пользователь  $u$  кликнул рекламное объявление  $b$  на веб-странице  $d$
- **Данные рекомендательной системы:**  
 $(u, f, s)$  — пользователь  $u$  оценил фильм  $f$  в ситуативном контексте  $s$

**Хотим** объяснить наблюдаемую выборку рёбер гиперграфа латентными векторами тематики его вершин.

## Тематическая модель гиперграфа: определения и обозначения

$\Gamma = \langle V, E \rangle$  — ориентированный гиперграф.

$V = V^1 \sqcup \dots \sqcup V^M$  — разбиение вершин по модальностям

$M$  — множество модальностей:

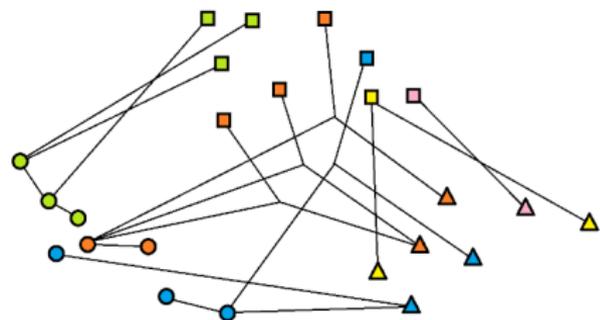
□ ○ △

$K$  — множество типов рёбер:

□○ □△ ○○ ○△ ○□△

$T$  — множество тем:

● ● ● ● ●



$X^k$  — наблюдаемая выборка транзакций — рёбер типа  $k$ ,

ребро  $(d, x)$ : вершина-контейнер  $d \in V$  и вершины  $x \subset V$ ,

$n_{dx}$  — число вхождений ребра  $(d, x)$  в выборку  $X^k$ ,

$p_k(d, x)$  — неизвестное распределение на рёбрах типа  $k$ .

## Тематическая модель гиперграфа

Вероятностная тематическая модель рёбер типа  $k$ :

$$p_k(x|d) = \sum_{t \in T} \theta_{td} \prod_{v \in X} \phi_{kvt},$$

$\theta_{td} = p(t|d)$  — тематика контейнера не зависит от типа ребра  $k$

$\phi_{kvt} = p_k(v|t)$  — для модальности  $v$  в теме  $t$  на рёбрах типа  $k$

**Задача** максимизации суммы  $\log$  правдоподобий с весами  $\tau_k$ :

$$\sum_{k \in K} \tau_k \sum_{(d,x) \in X^k} n_{dx} \ln \sum_{t \in T} \theta_{td} \prod_{v \in X} \phi_{kvt} \rightarrow \max_{\Phi, \Theta},$$

$$\phi_{kvt} \geq 0, \quad \sum_{v \in V^m} \phi_{kvt} = 1; \quad \theta_{td} \geq 0, \quad \sum_{t \in T} \theta_{td} = 1;$$

где  $\tau_k > 0$  — веса типов рёбер.

## EM-алгоритм для гиперграфовой ARTM

Задача максимизации регуляризованного правдоподобия:

$$\sum_{k \in K} \tau_k \sum_{(d,x) \in X^k} n_{dx} \ln \sum_{t \in T} \theta_{td} \prod_{v \in X} \phi_{kvt} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

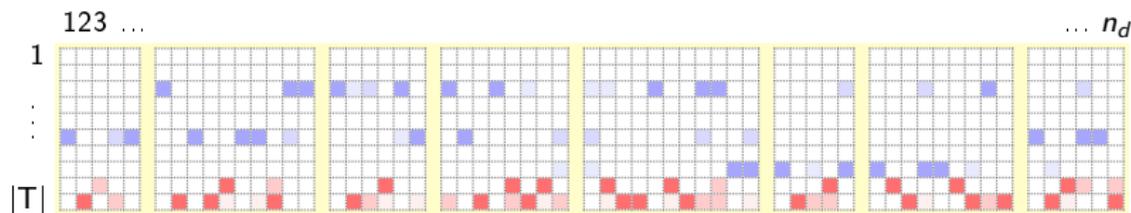
EM-алгоритм: метод простой итерации для системы уравнений со вспомогательными переменными  $p_{ktdx} = p_k(t|d, x)$ :

$$\begin{cases} \text{E-шаг:} & p_{ktdx} = \mathop{\text{norm}}_{t \in T} \left( \theta_{td} \prod_{v \in X} \phi_{kvt} \right) \\ \text{M-шаг:} & \begin{cases} \phi_{kvt} = \mathop{\text{norm}}_{v \in V^m} \left( \sum_{(d,x)} [v \in X] \tau_k n_{dx} p_{ktdx} + \phi_{kvt} \frac{\partial R}{\partial \phi_{kvt}} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{k \in K} \sum_{(d,x)} \tau_k n_{dx} p_{ktdx} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{cases} \end{cases}$$

## Тематическое моделирование последовательного текста

Документ  $d = \{w_1, \dots, w_{n_d}\}$ ,  $n_d$  — длина документа  $d$

Матрица тематики слов  $p(t|d, w_i)$  размера  $T \times n_d$ :



Предположения разреженности и непрерывности тематики:

- каждое предложение относится к 1–2 предметным темам
- соседние предложения часто имеют одинаковые темы
- слова общей лексики не влияют на тематику предложений
- между абзацами вероятность смены темы выше
- между секциями она ещё выше

## EM-алгоритм с регуляризацией E-шага

Позиционный регуляризатор  $R_{di}$  зависит от позиции слова  $i$  в документе  $d$  и от параметров  $\Phi, \Theta$  через  $p_{tdw} = \frac{\phi_{wt}\theta_{td}}{\sum_s \phi_{ws}\theta_{sd}}$ ,

$$\mathcal{L}(\Phi, \Theta) + \sum_{d \in D} \sum_{i=1}^{n_d} R_{di}(p_{1dw_i}, \dots, p_{Tdw_i}) + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}.$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\tilde{p}_{tdw} = p_{tdw} \frac{1}{n_{dw}} \sum_{\substack{i=1 \\ w_i=w}}^{n_d} \left( 1 + \frac{\partial R_{di}}{\partial p_{tdw}} - \sum_{s \in T} p_{sdw} \frac{\partial R_{di}}{\partial p_{sdw}} \right);$$

$$\phi_{wt} = \text{norm}_w \left( \sum_{d \in D} n_{dw} \tilde{p}_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right);$$

$$\theta_{td} = \text{norm}_t \left( \sum_{w \in d} n_{dw} \tilde{p}_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right).$$

## BigARTM: библиотека тематического моделирования

### Ключевые возможности:

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

### 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

## ARTM — альтернатива байесовскому подходу

ARTM унифицирует разработку моделей с заданными свойствами

### Этапы моделирования

#### 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

## Подзадачи, решаемые при построении тематических моделей

- Предобработка текста (лемматизация и не только)
- Инициализация EM-алгоритма
- Выбор стратегии регуляризации
- Подбор коэффициентов регуляризации
- Выбор критериев для контроля качества модели
- Подбор числа тем
- Построение тематических иерархий

На будущее:

- Автоматическая адаптация коэффициентов регуляризации
- Обеспечение полноты и устойчивости тем

## Тестирование 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

## Мультиязычная модель Википедии

216 175 русско-английских пар статей. Языки — модальности.  
 Первые 10 слов и их вероятности  $p(w|t)$  в %:

| Тема 68     |      |              |      | Тема 79 |      |           |      |
|-------------|------|--------------|------|---------|------|-----------|------|
| research    | 4.56 | институт     | 6.03 | goals   | 4.48 | матч      | 6.02 |
| technology  | 3.14 | университет  | 3.35 | league  | 3.99 | игрок     | 5.56 |
| engineering | 2.63 | программа    | 3.17 | club    | 3.76 | сборная   | 4.51 |
| institute   | 2.37 | учебный      | 2.75 | season  | 3.49 | фк        | 3.25 |
| science     | 1.97 | технический  | 2.70 | scored  | 2.72 | против    | 3.20 |
| program     | 1.60 | технология   | 2.30 | cup     | 2.57 | клуб      | 3.14 |
| education   | 1.44 | научный      | 1.76 | goal    | 2.48 | футболист | 2.67 |
| campus      | 1.43 | исследование | 1.67 | apps    | 1.74 | гол       | 2.65 |
| management  | 1.38 | наука        | 1.64 | debut   | 1.69 | забивать  | 2.53 |
| programs    | 1.36 | образование  | 1.47 | match   | 1.67 | команда   | 2.14 |

*Дударенко М. А.* Регуляризация многоязычных тематических моделей.  
 Вычислительные методы и программирование. 2015. Т. 16. С. 26–36.

## Мультиязычная модель Википедии

216 175 русско-английских пар статей. Языки — модальности.  
 Первые 10 слов и их вероятности  $p(w|t)$  в %:

| Тема 88     |      |         |      | Тема 251   |      |              |      |
|-------------|------|---------|------|------------|------|--------------|------|
| opera       | 7.36 | опера   | 7.82 | windows    | 8.00 | windows      | 6.05 |
| conductor   | 1.69 | оперный | 3.13 | microsoft  | 4.03 | microsoft    | 3.76 |
| orchestra   | 1.14 | дирижер | 2.82 | server     | 2.93 | версия       | 1.86 |
| wagner      | 0.97 | певец   | 1.65 | software   | 1.38 | приложение   | 1.86 |
| soprano     | 0.78 | певица  | 1.51 | user       | 1.03 | сервер       | 1.63 |
| performance | 0.78 | театр   | 1.14 | security   | 0.92 | server       | 1.54 |
| mozart      | 0.74 | партия  | 1.05 | mitchell   | 0.82 | программный  | 1.08 |
| sang        | 0.70 | сопрано | 0.97 | oracle     | 0.82 | пользователь | 1.04 |
| singing     | 0.69 | вагнер  | 0.90 | enterprise | 0.78 | обеспечение  | 1.02 |
| operas      | 0.68 | оркестр | 0.82 | users      | 0.78 | система      | 0.96 |

Ассессор оценил 396 тем из 400 как хорошо интерпретируемые.

## Биграммы радикально улучшают интерпретируемость тем

Коллекция 850 статей конференций ММРО, ИОИ на русском

| распознавание образов в биоинформатике |                         | теория вычислительной сложности |                      |
|--|-------------------------|---------------------------------|----------------------|
| unigrams                               | bigrams                 | unigrams                        | bigrams              |
| объект                                 | задача распознавания    | задача                          | разделять множества  |
| задача                                 | множество мотивов       | множество                       | конечное множество   |
| множество                              | система масок           | подмножество                    | условие задачи       |
| мотив                                  | вторичная структура     | условие                         | задача о покрытии    |
| разрешимость                           | структура белка         | класс                           | покрытие множества   |
| выборка                                | распознавание вторичной | решение                         | сильный смысл        |
| маска                                  | состояние объекта       | конечный                        | разделяющий комитет  |
| распознавание                          | обучающая выборка       | число                           | минимальный аффинный |
| информативность                        | оценка информативности  | аффинный                        | аффинный комитет     |
| состояние                              | множество объектов      | случай                          | аффинный разделяющий |
| закономерность                         | разрешимость задачи     | покрытие                        | общее положение      |
| система                                | критерий разрешимости   | общий                           | множество точек      |
| структура                              | информативность мотива  | пространство                    | случай задачи        |
| значение                               | первичная структура     | схема                           | общий случай         |
| регулярность                           | тупиговое множество     | комитет                         | задача MASC          |

Стенин С. С. Мультиграммные аддитивно регуляризованные тематические модели. Магистерская диссертация, МФТИ, 2015.

## Поиск этно-релевантных тем в социальных сетях

### Основные задачи проекта:

- Разведочный поиск этнических тем в социальных медиа
- Мониторинг этих тем во времени и по регионам
- Сентимент-анализ и оценивание конфликтности

### Примеры этнонимов:

|              |            |                     |
|--------------|------------|---------------------|
| османский    | русич      | ханты-мансийский    |
| карачаевский | сингапурец | восточноевропейский |
| эвенк        | перуанский | кубинка             |
| швейцарская  | словенский | гагаузский          |
| аланский     | вепсский   | темнокожий          |
| саамский     | негр       | нигериец            |
| латыш        | ниггер     | лягушатник          |
| литовец      | адыги      | камбоджиец          |
| цыганка      | абхаз      | сомалиец            |

## Примеры этно-релевантных тем

**(русские)**: русский, князь, россия, татарин, великий, царить, царь, иван, император, империя, грозить, государь, век, московская, екатерина, москва,

**(русские)**: акция, организация, митинг, движение, активный, мероприятие, совет, русский, участник, москва, оппозиция, россия, пикет, протест, проведение, националист, поддержка, общественный, проводить, участие,

**(славяне, византийцы)**: славянский, святослав, жрец, древние, письменность, рюрик, летопись, византия, мефодий, хазарский, русский, азбука,

**(сирийцы)**: сирийский, асад, боевик, район, террорист, уничтожить, группировка, дамаск, оружие, алесию, оппозиция, операция, селение, сша, нусра, турция,

**(турки)**: турция, турецкий, курдский, эрдоган, стамбул, страна, кавказ, горин, полиция, премьер-министр, регион, курдистан, ататюрк, партия,

**(иранцы)**: иран, иранский, сша, россия, ядерный, президент, тегеран, сирия, оон, израиль, переговоры, обама, санкция, исламский,

**(палестинцы)**: террорист, израиль, терять, палестинский, палестинец, террористический, палестина, взрыв, территория, страна, государство, безопасность, арабский, организация, иерусалим, военный, полиция, газ,

**(ливанцы)**: ливанский, боевик, район, ливан, армия, террорист, али, военный, хизбалла, раненый, уничтожить, сирия, подразделение, квартал, армейский,

**(ливийцы)**: ливан, демократия, страна, ливийский, каддафи, государство, алжир, война, правительство, сша, арабский, али, муаммар, сирия,

## Примеры этно-релевантных тем

**(евреи)**: израиль, израильский, страна, война, нетаньяху, тель-авив, время, сша, сирия, египет, случай, самолет, еврейский, военный, ближний,

**(американцы)**: американский, американка, война, россия, военный, страна, вашингтон, америка, армия, конгресс, сирия, союзный, российский, обама, войска, русский, оружие, операция,

**(немцы)**: армия, война, войска, советский, военный, дивизия, немец, фронт, немецкий, генерал, борт, операция, оборона, русский, бог, победа,

**(немцы)**: германий, немец, германский, ссср, немецкий, война, старое, советский, россия, береза, русский, правительство, территория, полный, документ, вопрос, сорт, договор, отношение, франция,

**(евреи, немцы)**: еврей, еврейский, холодный, германий, антисемитизм, гетра, немец, синагога, сша, израиль, малиновского, комиссия, нацбол, документ, война, еврейка, миллион, украина,

**(украинцы, немцы)**: украинский, унс, оун, немец, немецкий, ковальков, хохол, волынский, бандера, организация, россиянин, советский, русский, польский, армия, шухевича, ровенский,

**(таджики, узбеки)**: мигрант, страна, россия, миграция, азия, нелегальный, миграционный, таджикистан, гастарбайтер, гражданка, трудовой, рабочий, фмс, коренево, среднее, узбекистан, таджик, проблема, русский, население,

**(канадцы)**: команда, игра, игрок, канадский, сезон, хоккей, сборная, играть, болельщик, победа, кубок, счет, забирать, хоккейный, выигрывать, хоккеист, чемпионат, шайба,

## Примеры этно-релевантных тем

**(японцы)**: японский, япония, корея, китайский, жилища, авария, фукусиму, цунами, сообщать, океан, станция, хатико, район, правительство, атомный,

**(норвежцы)**: дитя, ребенок, родиться, детский, семья, воспитанный, право, возраст, отец, воспитание, норвежский, родительский, родить, мальчик, взрослый, опека, сын,

**(венесуэльцы)**: куба, кастро, венесуэла, чавес, президент, уго, мадура, боливия, фидель, глава, латинский, венесуэльский, лидер, боливарианской, президентский, альенде, гевару,

**(китайцы)**: китайский, россия, производство, китаи, продукция, страна, предприятие, компания, технология, военный, регион, производить, производственный, промышленность, российский, экономический, кнр,

**(азербайджанцы)**: русский, азербайджан, азербайджанец, россия, азербайджанский, таксист, диаспора, анапа, народ, москва, страна, армянин, слово, рынок,

**(грузины)**: грузинский, спецназ, военный, август, баташева, российский, спецназовец, миротворец, операция, румын, бригада, миротворческий, абхазия, группа, войска, русский, цхинвале,

**(осетины)**: конституция, осетия, аминат, русский, осетинский, южный, северный, россия, война, республика, вопрос, алахай, российский, население, конфликт,

**(цыгане)**: наркотик, цыган, цыганка, хороший, место, страна, деньга, время, работать, жизнь, жить, рука, дом, цыганский, наркоманка,

## Результат: ARTM находит намного больше этно-тем

Число этно-релевантных тем, найденных моделью:

| модель | этно-тем | фон.тем | ++        | +-        | -+        | всего      |
|--------|----------|---------|-----------|-----------|-----------|------------|
| PLSA   | 300      |         | 9         | 11        | 18        | 38         |
| PLSA   | 400      |         | 12        | 15        | 17        | 44         |
| ARTM-1 | 200      | 100     | 18        | 33        | 20        | 71         |
| ARTM-1 | 250      | 150     | 21        | 27        | 20        | 68         |
| ARTM-2 | 200      | 100     | 28        | 23        | 23        | 74         |
| ARTM-2 | 250      | 150     | <b>38</b> | <b>42</b> | <b>30</b> | <b>104</b> |

Регуляризаторы ARTM-1:

**этно темы:** разреживание, декоррелирование, сглаживание этнонимов

**фоновые темы:** сглаживание, разреживание этнонимов

Регуляризаторы ARTM-2:

ARTM-1 + **модальность этнонимов**

## Приложения

- Сфокусированный тематический поиск в социальных сетях
- Разведочный поиск научно-технической информации
- Тематизация коллекции научных статей ММРО/ИОИ
- Тематизация новостных потоков для медиапланирования
- Сценарный анализ записей разговоров колл-центра
- Кросс-язычный разведочный поиск arXiv.org+Википедия
- Тематизация картин британского музея и их описаний
- Классификация авторефератов по областям знаний
- Информационный анализ электрокардиосигналов
- Поиск мотивов в задачах биоинформатики



<http://bigartm.org>

-  *K. Vorontsov*. Additive regularization for topic models of text collections. 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. (на рецензии)