

# Задачи математического программирования в анализе текстов

Воронцов Константин Вячеславович  
(МФТИ, ФИЦ ИУ РАН, Сбербанк)

IX Московская международная конференция  
по исследованию операций  
(ORM-2018 Germeyer-100)

Москва • 22–27 октября 2018

- 1 Вероятностное тематическое моделирование**
  - Задача тематического моделирования
  - Аддитивная регуляризация и дальнейшие обобщения
  - Проект с открытым кодом BigARTM
- 2 Тематизация текстов и графов**
  - Дистрибутивная семантика
  - Тематические векторные представления слов
  - Тематическая модель гиперграфа
- 3 Тематизация транзакционных данных**
  - Транзакции физических лиц
  - Транзакции юридических лиц

## Приложения тематического моделирования

Тематическое моделирование — это «мягкая кластеризация» больших текстовых коллекций.


разведочный поиск в электронных библиотеках




персонализированный поиск в соцсетях



мультимодальный поиск текстов и изображений



детектирование и трекинг новостных сюжетов



навигация по большим текстовым коллекциям



управлением диалогом в разговорном интеллекте



## Пример. Мультиязычная модель Википедии

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

Ассессор оценил 396 тем из 400 как хорошо интерпретируемые.

*Vorontsov, Frei, Apishev, Romov, Suvorova.* BigARTM: Open Source Library for Regularized Multimodal Topic Modeling of Large Collections. AIST-2015.

## Пример. Мультиязычная модель Википедии

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

*Vorontsov, Frei, Apishev, Romov, Suvorova*. BigARTM: Open Source Library for Regularized Multimodal Topic Modeling of Large Collections. AIST-2015.

## Пусть

- $W$  — конечное множество слов (терминов, токенов)
- $D$  — конечное множество текстовых документов
- $T$  — конечное множество тем
- каждое слово  $w$  в документе  $d$  связано с некоторой темой  $t$
- $D \times W \times T$  — дискретное вероятностное пространство
- порядок слов в документе не важен (bag of words)
- порядок документов в коллекции не важен
- 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:  $p(w|d, t) = p(w|t)$


Тематическая модель, по формуле полной вероятности:

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

## 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  $t$ :

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



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

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:** коллекция текстовых документов

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

**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:



## Принцип максимума правдоподобия

Правдоподобие — плотность распределения выборки  $(d_i, w_i)_{i=1}^n$ :

$$\prod_{i=1}^n p(d_i, w_i) = \prod_{d \in D} \prod_{w \in d} p(d, w)^{n_{dw}}$$

Максимизация логарифма правдоподобия

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \ln p(w|d) \xrightarrow{p(d) = \text{const}} \max_{\Phi, \Theta}$$

эквивалентна максимизации функционала

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

при ограничениях неотрицательности и нормировки

$$\phi_{wt} \geq 0; \quad \sum_{w \in W} \phi_{wt} = 1; \quad \theta_{td} \geq 0; \quad \sum_{t \in T} \theta_{td} = 1.$$

## 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  $p_{tdw} = p(t|d, w)$ :

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

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

## Тематические векторные представления слов и документов

- Коллекция текстов — двудольный граф с рёбрами  $(d, w)$
- Слово  $w$  встречается в  $d$ , когда у них есть общие темы
- Интерпретируемость тем возникает благодаря  $p(w|t)$



## Задачи, некорректно поставленные по Адамару

Задача *корректно поставлена*,  
если её решение

- существует,
- единственно,
- устойчиво.



Жак Саломон Адамар  
(1865–1963)

Наша задача матричного разложения *некорректно поставлена*:  
если  $\Phi, \Theta$  — решение, то стохастические  $\Phi', \Theta'$  — тоже решения

- $\Phi'\Theta' = (\Phi S)(S^{-1}\Theta)$ ,  $\text{rank } S = |T|$
- $\mathcal{L}(\Phi', \Theta') = \mathcal{L}(\Phi, \Theta)$
- $\mathcal{L}(\Phi', \Theta') \leq \mathcal{L}(\Phi, \Theta) + \varepsilon$  — приближённые решения

**Регуляризация** — стандартный приём доопределения решения  
с помощью дополнительных критериев.

## ARTM — Аддитивная Регуляризация Тематических Моделей

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

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


EM-алгоритм: метод простой итерации для системы уравнений

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

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


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

## Регуляризаторы для улучшения интерпретируемости тем




Сглаживание фоновых тем  $B \subset T$ :

$$R(\Phi, \Theta) = \beta_0 \sum_{t \in B} \sum_w \beta_w \ln \phi_{wt} + \alpha_0 \sum_d \sum_{t \in B} \alpha_t \ln \theta_{td}$$




Разреживание предметных тем  $S = T \setminus B$ :

$$R(\Phi, \Theta) = -\beta_0 \sum_{t \in S} \sum_w \beta_w \ln \phi_{wt} - \alpha_0 \sum_d \sum_{t \in S} \alpha_t \ln \theta_{td}$$



Декоррелирование для повышения различности тем:

$$R(\Phi) = -\frac{\tau}{2} \sum_{t,s} \sum_w \phi_{wt} \phi_{ws}$$



Сглаживание + разреживание + декоррелирование  
для улучшения интерпретируемости тем

## Иерархические, темпоральные, регрессионные модели


hierarchy



Связь родительских тем  $t$  с дочерними подтемами  $s$ :

$$R(\Phi, \Psi) = \tau \sum_{t \in T} \sum_{w \in W} n_{wt} \ln \sum_{s \in S} \phi_{ws} \psi_{st}.$$


temporal



Темпоральные модели с модальностью времени  $i$ :

$$R(\Phi) = -\tau \sum_{i \in I} \sum_{t \in T} |\phi_{it} - \phi_{i-1,t}|.$$


regression



Линейная модель регрессии  $\hat{y}_d = \langle v, \theta_d \rangle$  документов:

$$R(\Theta, v) = -\tau \sum_{d \in D} \left( y_d - \sum_{t \in T} v_t \theta_{td} \right)^2.$$

n of topics




Разреживание  $p(t)$  для отбора тем:

$$R(\Theta) = -\tau \sum_{t \in T} \frac{1}{|T|} \ln p(t), \quad p(t) = \sum_{d \in D} p(d) \theta_{td}.$$

# Задачи мультимодального тематического моделирования

Темы определяют распределения не только терминов  $p(w|t)$ , но и других модальностей:  $p(\text{автор}|t)$ ,  $p(\text{время}|t)$ ,  $p(\text{ссылка}|t)$ ,  $p(\text{баннер}|t)$ ,  $p(\text{элемент\_изображения}|t)$ ,  $p(\text{пользователь}|t)$ , ...



## Мультимодальная ARTM

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

Максимизация суммы  $\log$  правдоподобий с регуляризацией:

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


EM-алгоритм: метод простой итерации для системы уравнений

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

*K.Vorontsov, O.Frei, M.Apishev et al.* Non-bayesian additive regularization for multimodal topic modeling of large collections. CIKM TM workshop, 2015.


## Мультимодальные тематические векторные представления

- Документы содержат слова и токены других *модальностей*
- Примеры модальностей: авторы, время, теги, пользователи, ...
- Через темы смыслы слов передаются другим модальностям




## Регуляризаторы для мультимодальных тематических моделей

supervised



Модальности меток классов или категорий для задач классификации и категоризации текстов.


multilanguage



Модальность языков и регуляризация со словарём  $\pi_{uwt} = p(u|w, t)$  переводов с языка  $k$  на  $l$ :

$$R(\Phi, \Pi) = \tau \sum_{u \in W^k} \sum_{t \in T} n_{ut} \ln \sum_{w \in W^l} \pi_{uwt} \phi_{wt}$$

temporal



Темпоральные модели с модальностью времени  $i$ :

$$R(\Phi) = -\tau \sum_{i \in I} \sum_{t \in T} |\phi_{it} - \phi_{i-1,t}|$$

geospatial



Модальность геолокаций  $g$  с близостью  $S_{gg'}$ :

$$R(\Phi) = -\frac{\tau}{2} \sum_{g, g' \in G} S_{gg'} \sum_{t \in T} n_t^2 \left( \frac{\phi_{gt}}{n_g} - \frac{\phi_{g't}}{n_{g'}} \right)^2$$

## Пример. Модальность $n$ -грамм улучшает качество тем

Коллекция 1000 статей конференций MMPO, 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	тупиковое множество	комитет	задача MASC

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

## Сегментная структура текста и пост-обработка E-шага

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

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



## Регуляризация E-шага

Трёхмерная матрица  $\Pi = (p_{tdw} = p(t|d, w))_{T \times D \times W}$

Максимизация  $\log$  правдоподобия с регуляризаторами  $R$  и  $\tilde{R}$ :

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} + R(\Pi(\Phi, \Theta)) + \tilde{R}(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}.$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{cases} \text{E-шаг:} & \left\{ \begin{array}{l} p_{tdw} = \operatorname{norm}_{t \in T}(\phi_{wt} \theta_{td}) \\ \tilde{p}_{tdw} = p_{tdw} \left( 1 + \frac{1}{n_{dw}} \left( \frac{\partial R(\Pi)}{\partial p_{tdw}} - \sum_{z \in T} p_{zdw} \frac{\partial R(\Pi)}{\partial p_{zdw}} \right) \right) \end{array} \right. \\ \text{M-шаг:} & \left\{ \begin{array}{l} \phi_{wt} = \operatorname{norm}_{w \in W} \left( \sum_{d \in D} n_{dw} \tilde{p}_{tdw} + \phi_{wt} \frac{\partial \tilde{R}}{\partial \phi_{wt}} \right) \\ \theta_{td} = \operatorname{norm}_{t \in T} \left( \sum_{w \in d} n_{dw} \tilde{p}_{tdw} + \theta_{td} \frac{\partial \tilde{R}}{\partial \theta_{td}} \right) \end{array} \right. \end{cases}$$

## Гипотеза: пост-обработка E-шага — это неявная регуляризация

Между E- и M-шагом добавляется обработка матрицы  $p_{tdw} = p(t|d, w)$  тематики слов документа:

$$\tilde{p}_{tdw} = p_{tdw} \left( 1 + \frac{1}{n_{dw}} \left( \frac{\partial R(\Pi)}{\partial p_{tdw}} - \sum_{z \in T} p_{zdw} \frac{\partial R(\Pi)}{\partial p_{zdw}} \right) \right) \quad (1)$$

Пост-обработка E-шага позволяет учитывать порядок слов в каждом документе в обход гипотезы «мешка слов».

### Гипотеза

Любое «разумное» преобразование  $p_{tdw} \rightarrow \tilde{p}_{tdw}$  эквивалентно некоторому регуляризатору  $R(\Pi(\Phi, \Theta))$ .

**Открытый вопрос:** при каких условиях по заданным  $p_{tdw}$  и  $\tilde{p}_{tdw}$  возможно подобрать функцию  $R(\Pi)$  так, чтобы выполнялось уравнение пост-обработки (1)?

## Регуляризаторы для моделирования последовательного текста

n-gram



Модели с модальностями  $n$ -грамм, коллокаций, именованных сущностей (например, TopMine)

syntax



Модели, учитывающие результаты автоматического синтаксического разбора (например, SyntaxNet)

coherence




Модели дистрибутивной семантики на основе совстречаемости слов (битермы, когерентность)

sentence



Тематические модели, учитывающие границы предложений, абзацев и секций документов

segmentation



Тематические модели сегментации с автоматическим определением границ сегментов

## 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:

- Свободная коммерческая лицензия (BSD 3-Clause)
- Кросс-платформенность: Windows, Linux, MacOS (32/64 bit)
- Интерфейсы API: command-line, C++, and Python

## Ключевые механизмы BigARTM

- 1 PLSA, LDA
- 2 регуляризация
- 3 модальности
- 4 иерархия тем
- 5 пост-обработка E-шага
- 6 встречаемость термов
- 7 гиперграфы транзакций



## Качество и скорость: BigARTM vs Gensim и Vowpal Wabbit

3.7М статей Википедии, 100К слов

	проц.	$T = 50$		$T = 200$	
		минут	перплексия	минут	перплексия
BigARTM	1	42	5117	83	3347
BigARTM async	1	25	5131	53	3362
VowpalWabbit	1	50	5413	154	3960
Gensim	1	142	4945	637	3241
BigARTM	4	12	5216	26	3520
BigARTM async	4	7	5353	16	3634
Gensim	4	88	5311	315	3583
BigARTM	8	8	5648	15	3929
BigARTM async	8	5	6220	10	4309
Gensim	8	88	6344	288	4263

*D.Kochedykov, M.Apishev, L.Golitsyn, K.Vorontsov.* Fast and Modular Regularized Topic Modelling. FRUCT ISMW, 2017.

## BigARTM упрощает разработку тематических моделей

Для построения сложных моделей в BigARTM не нужны ни математические выкладки, ни программирование «с нуля».

### 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

 -- стандартизуемые этапы

## Задача семантического векторного представления слов

Найти для каждого слова  $w$  вектор  $x_w \in \mathbb{R}^T$ , чтобы близкие по смыслу слова имели близкие векторы.

**Задача семантической аналогии слов:**  
по трём словам угадать четвёртое.



## Дистрибутивная гипотеза

- Words that occur in the same contexts tend to have similar meanings [Harris, 1954].
- You shall know a word by the company it keeps [Firth, 1957].

*Синтагматическая близость слов:*

со-встречаемость слов в одном контексте.



здание–строитель, кран–вода, функция–точка

*Парадигматическая близость слов:*

взаимозаменяемость слов в одном контексте.



здание–дом, кран–смеситель, функция–отображение

---

*Z.Harris.* Distributional structure. 1954.

*J.R.Firth.* A synopsis of linguistic theory 1930-1955. Oxford, 1957.

*P.D.Turney, P.Pantel.* From frequency to meaning: Vector space models of semantics // Journal of Artificial Intelligence Research (JAIR). 2010.

## Формализация дистрибутивной гипотезы в программе word2vec

**Дано:**  $n_{uw}$  — встречаемость слов  $u, w$  в окне  $\pm h$  слов

**Найти:** семантические векторные представления слов  $x_w$

**Модель:** вероятность слова  $w$  в контексте слова  $u$ :

$$p(w|u) = \text{SoftMax}_{w \in W} \langle x_w, x_u \rangle = \frac{\exp \langle x_w, x_u \rangle}{\sum_v \exp \langle x_v, x_u \rangle}$$

**Критерий** максимума log-правдоподобия и его аппроксимация:

$$\sum_{w, u \in W} n_{wu} \ln p(w|u) \rightarrow \max_{\{x_w\}}$$

$$\sum_{w, u \in W} n_{wu} \left( \ln \sigma \langle x_w, x_u \rangle + \sum_{i=1}^k \ln \sigma(-\langle x_{v_i}, x_u \rangle) \right) \rightarrow \max_{\{x_w\}}$$

где  $v_1, \dots, v_k$  — случайные  $k$  слов не из контекста  $u$ .

---

*T. Mikolov, K. Chen, G. Corrado, J. Dean. Efficient estimation of word representations in vector space, 2013.*

## Модели векторных представлений для текстов и графов

**word2vec**: эмбединги слов

*T.Mikolov et al.* Efficient estimation of word representations in vector space. 2013.

**paragraph2vec**: эмбединги фрагментов или документов

*Q.Le, T.Mikolov.* Distributed representations of sentences and documents. 2014.

**sent2vec**: эмбединги предложений

*M.Pagliardini et al.* Unsupervised learning of sentence embeddings using compositional n-gram features. 2017.

**FastText**: эмбединги символьных  $n$ -грамм

<https://github.com/facebookresearch/fastText>

**node2vec**: эмбединги вершин графа

*A.Grover, J.Leskovec.* Node2vec: scalable feature learning for networks. 2016.

**graph2vec**: более общие эмбединги на графах

*A.Narayanan et al.* Graph2vec: learning distributed representations of graphs. 2017.

**StarSpace**: эмбединги чего угодно от Facebook AI Research

*L.Wu, A.Fisch, S.Chopra, K.Adams, A.B.J.Weston.* StarSpace: embed all the things! 2018.

**Недостаток:** координаты векторов не интерпретируемы


## Модель сети слов WNTM для коротких текстов

**Идея:** моделировать не документы, а связи между словами.

$d_u$  — псевдо-документ, объединение всех контекстов слова  $u$ .

$n_{uw}$  — число вхождений слова  $w$  в псевдо-документ  $d_u$ .

**Контекст** — короткое сообщение / предложение / окно  $\pm h$  слов.



*Yuan Zuo, Jichang Zhao, Ke Xu. Word Network Topic Model: a simple but general solution for short and imbalanced texts. 2014.*

## Модели WNTM и WTM (Word Topic Model)

Тематическая модель контекстов, разложение  $W \times W$ -матрицы:

$$p(w|d_u) = \sum_{t \in T} p(w|t)p(t|d_u) = \sum_{t \in T} \phi_{wt}\theta_{tu},$$

где  $d_u$  — псевдо-документ слова  $u$ .

Максимизация логарифма правдоподобия:

$$\sum_{u, w \in W} n_{uw} \log \sum_{t \in T} \phi_{wt}\theta_{tu} \rightarrow \max_{\Phi, \Theta},$$

где  $n_{uw}$  — совстречаемость слов  $u, w$  (кстати,  $n_{uw} = n_{wu}$ ).


---

*Yuan Zuo, Jichang Zhao, Ke Xu.* **Word Network Topic Model**: a simple but general solution for short and imbalanced texts. 2014.

*Berlin Chen.* **Word Topic Models** for spoken document retrieval and transcription. ACM Trans., 2009.

## Интерпретируемые эмбединги совстречаемости слов


- Идея дистрибутивной семантики: “Words that occur in the same contexts tend to have similar meanings” [Harris, 1954].
- Слово индуцирует псевдо-документ всех его контекстов



## word2vec и ARTM в задаче семантической близости документов

ArXiv triplets dataset: 20К троек статей:

$\langle$  статья A, схожая статья B, непохожая статья C  $\rangle$



- обучение по 1М текстов статей ArXiv
- тестирование на триплетах ArXiv
- Конкурент DBOW: paragraph2vec [Dai et. al, 2015]

ARTM превосходит модель DBOW (distributed bag-of-words).

---

*Andrew Dai, Cristopher Olah, Quoc Le.* Document Embedding with Paragraph Vectors, CoRR, 2015

*A.Potapenko, A.Popov, K.Vorontsov.* Interpretable probabilistic embeddings: bridging the gap between topic models and neural networks. AINL-6, 2017.

## Транзакционные данные

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

**Примеры:**

- **Данные социальной сети:**  
 $(d, u, w)$  — пользователь  $u$  записал слово  $w$  в блоге  $d$
- **Данные сети интернет-рекламы:**  
 $(u, d, b)$  — пользователь  $u$  кликнул баннер  $b$  на странице  $d$
- **Данные рекомендательной системы:**  
 $(u, f, s)$  — пользователь  $u$  оценил фильм  $f$  в ситуации  $s$
- **Данные финансовых организаций:**  
 $(b, s, g)$  — покупатель  $u$  купил у продавца  $s$  товар  $g$

**Задача:** по наблюдаемой выборке рёбер гиперграфа выявить латентные темы 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:


$\square \quad \circ \quad \Delta$

$K$  — множество типов рёбер:

$\square \circ \quad \square \Delta \quad \circ \circ \quad \circ \Delta \quad \square \Delta$

$T$  — множество тем:

$\bullet \quad \bullet \quad \bullet \quad \bullet \quad \bullet$



$X^k$  — 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  $X^k$

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

## Тематическая модель гиперграфа

Вероятностная тематическая модель рёбер типа  $k$ :

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

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

$\phi_{vt} = p(v|t)$  — распределение термов модальности  $v$  в теме  $t$

Задача максимизации  $\log$  правдоподобия:

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

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

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

## EM-алгоритм для гиперграфовой ARTM

Задача максимизации регуляризованного правдоподобия:


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

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

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

## Интерпретируемые эмбединги транзакционных данных

- *Гиперграф* — множество подмножеств вершин-токенов
- Транзакция = подмножество токенов = ребро гиперграфа
- Транзакция происходит, когда токены имеют общие темы



## Модели предложений и коротких текстов TwitterLDA, senLDA

$S_d$  — множество предложений документа  $d$

$n_{sw}$  — сколько раз терм  $w$  встречается в предложении  $s$

Тематическая модель предложения  $s$ :

$$p(s|d) = \sum_{t \in T} p(t|d) \prod_{w \in s} p(w|t)^{n_{sw}} = \sum_{t \in T} \theta_{td} \prod_{w \in s} \phi_{wt}^{n_{sw}}$$

Максимизация регуляризованного log-правдоподобия

$$\sum_{d \in D} \sum_{s \in S_d} \ln \sum_{t \in T} \theta_{td} \prod_{w \in s} \phi_{wt}^{n_{sw}} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

это частный случай гиперграфовой модели, в которой предложения являются «транзакциями» или гипер-рёбрами.


---

Wayne Xin Zhao, Jing Jiang, Jianshu Weng, Jing He, Ee Peng Lim et al.  
Comparing Twitter and traditional media using topic models. ECIR 2011.

G.Balikas, M.-R.Amini, M.Clausel. On a topic model for sentences. SIGIR 2016.

## Интерпретируемые эмбединги предложений

- Предложение — семантически однородная единица языка
- Предложение образуется из слов, имеющих общие темы
- Предложение = подмножество слов = ребро гиперграфа



## Анализ данных о транзакциях клиентов банка

**Дано** (Sberbank Data Science Contest):

$D$  — 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

## 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
  - 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, периферия, программное обеспечение
  - 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
  - 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 Авиалинии, 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 50 категорий с  $\phi_{wt} > 0.1\%$ ; 103 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, лизинг
- 2.2 Товары для дома
- 2.1 Пассажирские железнодорожные перевозки
- 1.5 Оборудование, мебель и бытовые принадлежности
- 1.3 Скобяные товары в розницу
- 1.2 Магазины спорттоваров
- 1.1 Аптеки

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

## Анализ данных о транзакциях клиентов банка

### Данные:

лесная отрасль, 2016 г., 10.7М транзакций, 1М компаний.

Транзакция — это тройка ⟨покупатель, продавец, текст⟩.

Некоторые *тексты* платёжных поручений (далеко не все!) содержат названия товаров и услуг.

Документ — это история транзакций одной компании

### Четыре модальности:

- компании-поставщики
- слова в текстах транзакций покупки
- компании-покупатели
- слова в текстах транзакций продажи

## Примеры тем — видов деятельности компаний

покупка	продажа
0.11: услуга	0.12: лдсп
0.07: классик	0.08: дсп
0.05: дрова	0.03: мдф
0.05: пиловочник	0.03: поставка
0.05: материал	0.02: услуга
0.03: порода	0.02: охранный
0.03: лесоматериал	0.02: ламинировать
0.03: сертум	0.02: хдф
0.02: хвойный	0.02: материал
0.01: дерево	0.01: накл
0.01: транспортный	0.01: товар

покупка	продажа
0.19: право	0.16: арендный
0.17: сбис	0.10: часть
0.16: использование	0.08: плата
0.03: аккаунт	0.04: минимальный
0.02: электронный	0.04: участок
0.02: лицевой	0.04: использование
0.02: устный	0.02: земля
0.01: устройство	0.02: лесничество
0.01: генерация	0.02: земельный
0.01: хранение	0.01: фонд
0.01: ключевой	0.01: федеральный

## Примеры тем — видов деятельности компаний

покупка	продажа
0.09: ткань	0.16: мебель
0.09: поставка	0.05: плёнка
0.02: мебельный	0.04: стул
0.02: деревянный	0.03: кресло
0.02: транспортный	0.03: изделие
0.02: фанера	0.02: краска
0.02: поролон	0.02: фанера
0.01: механизм	0.01: лкм
0.01: плата	0.01: лакокрасочный
0.01: частичный	0.01: лак
	0.01: материал
	0.01: клеить

покупка	продажа
0.06: лдсп	0.37: товар
0.05: фурнитура	0.15: мебель
0.02: плёнка	0.04: поставка
0.02: материал	0.04: накладный
0.02: мебельный	0.03: накл
0.02: стекло	0.03: рубль
0.02: мдф	
0.02: кромка	
0.01: транспортный	
0.01: клеить	
0.01: профиль	
0.01: пвх	

## Примеры тем — видов деятельности компаний

<b>покупка</b>	<b>продажа</b>
0.52: гсм	0.14: вывоз
0.43: далее	0.09: тбо
	0.04: мусор
	0.03: отход
	0.02: утилизация
	0.01: тко

<b>покупка</b>	<b>продажа</b>
0.19: налог	0.11: бумага
0.06: услуга	0.08: гофроящик
0.04: макулатура	0.04: гофрокартон
0.03: поставка	0.03: гофрокороб
0.03: транспортный	0.03: поставка
0.02: лесопродукция	0.03: фактура
0.02: автоуслуга	0.02: гофропродукция
0.01: перевозка	0.02: гофротару
0.01: плата	0.02: гофрирование
	0.02: гофролоток
	0.02: товар
	0.01: лоток

## Примеры тем — видов деятельности компаний

покупка

0.15: программа

0.11: право

0.09: сертификат

0.07: эвм

0.07: использование

0.07: лицензия

0.04: криптопро

0.03: абонентский

0.02: услуга

0.02: пользование

0.02: контур

0.01: проверка

продажа

0.13: фурнитура

0.09: материал

0.08: лдсп

0.04: кромка

0.04: мебельный

0.04: фрз

0.04: мдф

0.03: клеить

0.03: пвх

0.02: тмц

0.02: комплект

0.02: профиль

0.02: столешница

продажа

0.14: рекламный

0.13: размещение

0.09: материал

0.05: проект

0.05: яндекс

0.04: директ

0.04: реклама

0.02: рубль

0.01: стек

продажа

0.21: тмц

0.06: накл

0.04: инструмент

0.03: пила

0.02: заточка

0.02: нож

0.02: материал

0.02: фреза


0.02: клеить

0.01: товар

0.01: перчатка

## Конечные цели моделирования транзакционных данных

- Получение векторных представлений компаний
- Поиск схожих и конкурирующих компаний
- Восстановление структуры товарных потоков отрасли



-  *K.B.Воронцов*. Обзор вероятностных тематических моделей. 2018. – **NEW!**  
<http://www.MachineLearning.ru/wiki/images/d/d5/Voron17survey-artm.pdf>
-  *K.B.Воронцов*. Аддитивная регуляризация тематических моделей коллекций текстовых документов. Доклады РАН. 2014.
-  *K.Vorontsov, A.Potapenko*. Additive regularization of topic models. Machine Learning, 2015.
-  *O.Frei, M.Apishev*. Parallel non-blocking deterministic algorithm for online topic modeling. AIST 2016.
-  *N.Chirkova, K.Vorontsov*. Additive regularization for hierarchical multimodal topic modeling. JMLDA, 2016.
-  *A.Ianina, K.Vorontsov*. Multi-objective topic modeling for exploratory search in tech news. AINL, 2017.
-  *A.Potapenko, A.Popov, K.Vorontsov*. Interpretable probabilistic embeddings: bridging the gap between topic models and neural networks. AINL, 2017.
-  *V.Alekseev, V.Bulatov, K.Vorontsov*. Intra-Text Coherence as a Measure of Topic Models Interpretability. Dialogue, 2018.
-  *A.Belyy, M.Seleznova, A.Sholokhov, K.Vorontsov*. Quality Evaluation and Improvement for Hierarchical Topic Modeling. Dialogue, 2018.
-  *N.Skachkov, K.Vorontsov*. Improving topic models with segmental structure of texts. Dialogue, 2018.