

# Towards bridging the gap between Probabilistic Topic Models and Large Language Models

Konstantin Vorontsov, Ilya Irkhin, Ilya Dyakov

Dr.Sc.(phys.-math.), professor of RAS,  
*head of Machine Learning & Semantic Analysis laboratory at  
Institute for Artificial Intelligence, Moscow State University;  
head of department “Mathematical Methods of Forecasting”, MSU;  
head of department “Machine Learning & Digital Humanities”, MIPT  
([k.vorontsov@iai.msu.ru](mailto:k.vorontsov@iai.msu.ru))*

MathAI 2025 • Int. Conf. Mathematics in Artificial Intelligence  
Sirius International Mathematical Center • Sochi • 24–28 March 2025

## 1 Вероятностное тематическое моделирование

- постановка задачи
- приложения и область исследований
- сходства и отличия от LLM

## 2 Аддитивная регуляризация и обобщения

- оптимизация на единичных симплексах
- аддитивная регуляризация тематических моделей
- гиперграфовая тематическая модель

## 3 На пути к тематической модели внимания

- тематическая модель линейного текста
- тематическая модель локальных контекстов
- эксперименты

## Тематическое моделирование: «о чём все эти тексты?»

**Дано:** коллекция текстовых документов как «мешков-слов»

- $n_{dw}$  — частота слов (термов)  $w \in W$  в документе  $d \in D$
- $|T|$  — сколько тем хотим определить в коллекции  $D$

**Найти:** тематическую языковую модель


- $p(w|d) = \sum_{t \in T} p(w|\cancel{d}, t) p(t|d) = \sum_{t \in T} \phi_{wt} \theta_{td}$
- $p(w|t) = \phi_{wt}$  — из каких слов  $w$  состоит каждая тема  $t \in T$
- $p(t|d) = \theta_{td}$  — из каких тем  $t$  состоит каждый документ  $d$

**Критерий:** правдоподобие предсказания слов  $w$  в документах  $d$  с дополнительными критериями-регуляризаторами  $R_i(\Phi, \Theta)$ :

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

## Три интерпретации задачи тематического моделирования

1. **Мягкая кластеризация** документов по кластерам-темам
2. **Матричное разложение** — низкоранговое, стохастическое:




3. **Автокодировщик** документов в тематические эмбеддинги:

- кодировщик  $f_\Phi: \frac{n_{dw}}{n_d} \rightarrow \theta_d$
- декодировщик  $g_\Phi: \theta_d \rightarrow \Phi\theta_d$

задача реконструкции:

$$\sum_{d,w} n_{dw} \ln \langle \phi_w, \theta_d \rangle \rightarrow \min_{\Phi, \Theta}$$



## Цели и не-цели тематического моделирования

### Цели:

- выявлять тематическую кластерную структуру текстовой коллекции (сколько в ней тем и о чём они), представлять результат в удобной для человека форме
- получать интерпретируемые тематические векторы (эмбединги) слов  $p(t|w)$ , слов-в-контексте  $p(t|d, w)$ , документов  $p(t|d)$ , фрагментов  $p(t|s)$ , объектов  $p(t|x)$
- решать с их помощью задачи поиска, фильтрации, категоризации, сегментации, суммаризации текстов

### Не-цели:

- угадывать слова по контексту (это слабые модели языка)
- понимать смысл текста
- генерировать связный текст

## Некоторые приложения тематического моделирования


разведочный поиск в электронных библиотеках



поиск тематических сообществ в соцсетях



выявление и отслеживание цепочек новостей




мультимодальный поиск текстов и изображений



анализ банковских транзакционных данных



поиск паттернов в задачах биоинформатики




J.Boyd-Graber, Yuening Hu, D.Mimno. Applications of Topic Models. 2017.

H.Jelodar et al. Latent Dirichlet allocation (LDA) and topic modeling: models, applications, a survey. 2019.

## Научные тренды: PTM, LLM и смежные с ними

Динамика цитирования (по данным Google Scholar):  
Topic Modeling и смежные области исследований:



Rob Churchill, Lisa Singh. The Evolution of Topic Modeling. November, 2022.  
He Zhao et al. Topic Modelling Meets Deep Neural Networks: A Survey. 2021

## Эволюция тематического моделирования



Neural Topic Models — поток публикаций начиная с 2016

Как «объединить лучшее от двух миров»?

- **Neural:** качество, универсальность, генеративность
- **Topic:** скорость, интерпретируемость, простота

**Что объединяет:** векторизация, оптимизация, регуляризация, гомогенизация, локализация (контекст и внимание)

## Сходства и отличия от LLM

### РТМ и LLM — что общего

- языковая модель, которая предсказывает слова в тексте
- автокодировщик, который переводит текст в эмбединги
- мультимодальность, мультиязычность данных
- многозадачность, многокритериальность обучения

### РТМ — принципиальные отличия от LLM

- намного более слабая языковая модель
- эмбединги вероятностные, разреженные, интерпретируемые
- простота и скорость матричного разложения

### РТМ — дальнейшее развитие навстречу LLM

- отказ от байесовского обучения → совместимость с SG
- отказ от мешка слов → тематическая модель внимания
- данные на гиперграфе → гомогенизация эмбедингов

## Задача максимизации функции на единичных симплексах

Пусть  $\Omega = (\omega_j)_{j \in J}$  — набор нормированных неотрицательных векторов  $\omega_j = (\omega_{ij})_{i \in I_j}$  различных размерностей  $|I_j|$ :

$$\Omega = \left( \begin{array}{c} \text{[yellow]} \\ \text{[blue]} \\ \text{[blue]} \\ \text{[purple]} \\ \text{[purple]} \\ \text{[pink]} \\ \text{[pink]} \\ \text{[pink]} \\ \text{[green]} \\ \text{[green]} \\ \text{[green]} \end{array} \right)$$

Задача максимизации функции  $f(\Omega)$  на единичных симплексах:

$$\begin{cases} f(\Omega) \rightarrow \max_{\Omega}; \\ \sum_{i \in I_j} \omega_{ij} = 1, \quad j \in J; \\ \omega_{ij} \geq 0, \quad i \in I_j, \quad j \in J. \end{cases}$$

## Необходимые условия экстремума и метод простых итераций

Операция нормировки вектора:  $p_i = \text{norm}(x_i) = \frac{\max(x_i, 0)}{\sum_k \max(x_k, 0)}$

**Лемма.** Пусть  $f(\Omega)$  непрерывно дифференцируема по  $\Omega$ .

Если  $\omega_j$  — вектор локального экстремума нашей задачи и  $\exists i: \omega_{ij} \frac{\partial f}{\partial \omega_{ij}} > 0$ , то  $\omega_j$  удовлетворяет системе уравнений

$$\omega_{ij} = \text{norm}\left(\omega_{ij} \frac{\partial f}{\partial \omega_{ij}}\right).$$

- Численное решение системы — методом простых итераций
- Векторы  $\omega_j = 0$  отбрасываются как вырожденные решения
- Итерации похожи на градиентную оптимизацию:

$$\omega_{ij} := \omega_{ij} + \eta \frac{\partial f}{\partial \omega_{ij}},$$

но учитывают ограничения и не требуют подбора шага  $\eta$

## Напоминание. Условия Каруша–Куна–Таккера

Задача математического программирования:

$$\begin{cases} f(x) \rightarrow \min_x; \\ g_i(x) \leq 0, \quad i = 1, \dots, m; \\ h_j(x) = 0, \quad j = 1, \dots, k. \end{cases}$$

Необходимые условия. Если  $x$  — точка локального минимума, то существуют множители  $\mu_i$ ,  $i = 1, \dots, m$ ,  $\lambda_j$ ,  $j = 1, \dots, k$ :

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial x} = 0, \quad \mathcal{L}(x; \mu, \lambda) = f(x) + \sum_{i=1}^m \mu_i g_i(x) + \sum_{j=1}^k \lambda_j h_j(x); \\ g_i(x) \leq 0; \quad h_j(x) = 0; \quad (\text{исходные ограничения}) \\ \mu_i \geq 0; \quad (\text{двойственные ограничения}) \\ \mu_i g_i(x) = 0; \quad (\text{условие дополняющей нежёсткости}) \end{cases}$$

## Доказательство леммы о максимизации на симплексах

Задача:  $f(\Omega) \rightarrow \max_{\Omega}; \quad \sum_{i \in I_j} \omega_{ij} = 1, \quad \omega_{ij} \geq 0, \quad i \in I_j, \quad j \in J.$

Функция Лагранжа:

$$\mathcal{L}(\Omega; \mu, \lambda) = -f(\Omega) + \sum_{j \in J} \lambda_j \left( \sum_{i \in I_j} \omega_{ij} - 1 \right) - \sum_{j \in J} \sum_{i \in I_j} \mu_{ij} \omega_{ij}.$$

Условия Каруша–Куна–Таккера для вектора  $\omega_j$ :

$$\frac{\partial f(\Omega)}{\partial \omega_{ij}} = \lambda_j - \mu_{ij}, \quad \mu_{ij} \omega_{ij} = 0, \quad \mu_{ij} \geq 0.$$

Умножим обе части первого равенства на  $\omega_{ij}$ :

$$A_{ij} \equiv \omega_{ij} \frac{\partial f(\Omega)}{\partial \omega_{ij}} = \omega_{ij} \lambda_j.$$

Согласно условию леммы  $\exists i: A_{ij} > 0$ . Значит,  $\lambda_j > 0$ .

Если  $\frac{\partial f(\Omega)}{\partial \omega_{ij}} < 0$  для некоторого  $i$ , то  $\mu_{ij} > 0 \Rightarrow \omega_{ij} = 0$ .

Тогда  $\omega_{ij} \lambda_j = (A_{ij})_+; \quad \lambda_j = \sum_i (A_{ij})_+ \Rightarrow \omega_{ij} = \text{norm}_i(A_{ij}).$

## Теорема о сходимости итерационного процесса

$$\omega_{ij}^{t+1} = \operatorname{norm}_{i \in I_j} \left( \omega_{ij}^t \frac{\partial f(\Omega^t)}{\partial \omega_{ij}^t} \right)$$

**Теорема.** Пусть  $f(\Omega)$  — ограниченная сверху, непрерывно дифференцируемая функция, и все  $\Omega^t$ , начиная с некоторой итерации  $t^0$  обладают свойствами:

- $\forall j \in J \quad \forall i \in I_j \quad \omega_{ij}^t = 0 \rightarrow \omega_{ij}^{t+1} = 0$  (сохранение нулей)
- $\exists \varepsilon > 0 \quad \forall j \in J \quad \forall i \in I_j \quad \omega_{ij}^t \notin (0, \varepsilon)$  (отделимость от нуля)
- $\exists \delta > 0 \quad \forall j \in J \quad \exists i \in I_j \quad \omega_{ij}^t \frac{\partial f(\Omega^t)}{\partial \omega_{ij}} \geq \delta$  (невырожденность)
- $\exists \lambda > 0 \quad f(\Omega^{t+1}) - f(\Omega^t) \geq \lambda H(\Omega^t)$  (монотонный рост  $f$ )

Тогда  $|\omega_{ij}^{t+1} - \omega_{ij}^t| \rightarrow 0$  при  $t \rightarrow \infty$ .

## Открытая проблема: неудобное четвёртое условие

**Определение.**  $H(\Omega^t)$  есть линейное приближение приращения функции  $f$  в окрестности точки  $\Omega^t$ :

$$f(\Omega^{t+1}) - f(\Omega^t) = H(\Omega^t) + o(\Delta\Omega^t)$$

**Лемма.** Квадратичное представление функции  $H(\Omega)$ :

$$H(\Omega) = \frac{1}{2} \sum_{j \in J} \sum_{i, k \in I_j} \left( \frac{\partial f(\Omega)}{\partial \omega_{ij}} - \frac{\partial f(\Omega)}{\partial \omega_{kj}} \right)^2 \omega_{ij} \omega_{kj}$$

Следовательно,  $H(\Omega^t) \geqslant 0$ .

$f(\Omega^{t+1}) - f(\Omega^t) \approx H(\Omega^t)$  — согласно определению;

$f(\Omega^{t+1}) - f(\Omega^t) \geqslant \lambda H(\Omega^t)$ , начиная с некоторой итерации  $t$  при некотором  $\lambda > 0$  — хотелось бы получить это как результат, а не вводить как предположение. Доказать это пока не удалось.

---

A.M.Ostrowski. Solution of equations and systems of equations. New York, 1966.

## Промежуточные итоги и направления исследований

- Метод похож на обычную градиентную оптимизацию, но не требует подбора градиентного шага  $\eta$
- Ограничения неотрицательности и нормировки могут накладываться не на все векторы, а лишь на некоторые
- Операция `norm` может приводить к обнулению части координат, следовательно, к разреживанию векторов  $\omega_j$
- **Приложения:**
  - вероятностное тематическое моделирование
  - неотрицательные матричные разложения
  - монотонные нейронные сети
  - сети для аппроксимации функций распределения
- **Открытая проблема:** упростить четвёртое условие в теореме сходимости (оно представляется избыточным)
- **Открытая проблема:** оценить скорость сходимости

## Задачи, некорректно поставленные по Адамару

Задача корректно поставлена  
по Адамару, если её решение

- существует,
- единственно,
- устойчиво.



Жак Саломон Адамар  
(1865–1963)

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

- $\Phi'\Theta' = (\Phi S)(S^{-1}\Theta)$ ,  $\text{rank } S = |T|$
- $L(\Phi', \Theta') \approx L(\Phi, \Theta)$



**Регуляризация** — доопределение решения  
путём добавления критерия  $+ \tau R(\Phi, \Theta)$

**Скаляризация** критериев:  $+ \sum_i \tau_i R_i(\Phi, \Theta)$

А.Н. Тихонов  
(1906–1993)

## ARTM: аддитивная регуляризация тематических моделей

Максимизация логарифма правдоподобия **с регуляризатором**:

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

EM-алгоритм: метод простой итерации для системы уравнений

E-шаг:  $p_{tdw} \equiv p(t|d, w) = \text{norm}_{t \in T}(\phi_{wt} \theta_{td})$

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

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

## Доказательство (по лемме о максимизации на симплексах)

Применим лемму к log-правдоподобию с регуляризатором:

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

$$\begin{aligned}\phi_{wt} &= \underset{w \in W}{\text{norm}} \left( \phi_{wt} \frac{\partial f}{\partial \phi_{wt}} \right) = \underset{w \in W}{\text{norm}} \left( \cancel{\phi_{wt}} \sum_{d \in D} n_{dw} \frac{\theta_{td}}{p(w|d)} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right) = \\ &= \underset{w \in W}{\text{norm}} \left( \sum_{d \in D} n_{dw} \cancel{p_{tdw}} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right);\end{aligned}$$

$$\begin{aligned}\theta_{td} &= \underset{t \in T}{\text{norm}} \left( \theta_{td} \frac{\partial f}{\partial \theta_{td}} \right) = \underset{t \in T}{\text{norm}} \left( \cancel{\theta_{td}} \sum_{w \in W} n_{dw} \frac{\phi_{wt}}{p(w|d)} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) = \\ &= \underset{t \in T}{\text{norm}} \left( \sum_{w \in d} n_{dw} \cancel{p_{tdw}} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right).\end{aligned}$$

## PLSA и LDA — две самые известные тематические модели

**PLSA**: probabilistic latent semantic analysis [Hofmann, 1999]  
(вероятностный латентный семантический анализ):

$$R(\Phi, \Theta) = 0.$$

М-шаг — частотные оценки условных вероятностей:

$$\phi_{wt} = \text{norm}_w(n_{wt}), \quad \theta_{td} = \text{norm}_t(n_{td}).$$

**LDA**: latent Dirichlet allocation (латентное размещение Дирихле):

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

М-шаг — частотные оценки с поправками  $\beta_w > -1, \alpha_t > -1$ :

$$\phi_{wt} = \text{norm}_w(n_{wt} + \beta_w), \quad \theta_{td} = \text{norm}_t(n_{td} + \alpha_t).$$

---

Hofmann T. Probabilistic latent semantic indexing. SIGIR 1999.

Blei D., Ng A., Jordan M. Latent Dirichlet Allocation. NIPS-2001. JMLR 2003.

## Байесовская и классическая регуляризация

**Байесовский вывод** апостериорного распределения  $p(\Omega|X)$  (громоздкий, приближённый) ради точечной оценки  $\Omega$ :

$$\text{Posterior}(\Omega|X, \gamma) \propto p(X|\Omega) \text{Prior}(\Omega|\gamma)$$

$$\Omega := \arg \max_{\Omega} \text{Posterior}(\Omega|X, \gamma)$$


**Максимизация апостериорной вероятности** (MAP) даёт точечную оценку  $\Omega$  напрямую, без вывода Posterior:

$$\Omega := \arg \max_{\Omega} (\ln p(X|\Omega) + \ln \text{Prior}(\Omega|\gamma))$$

**Многокритериальная аддитивная регуляризация** (ARTM) обобщает MAP на любые регуляризаторы и их комбинации:


$$\Omega := \arg \max_{\Omega} (\ln p(X|\Omega) + \sum_{i=1}^k \tau_i R_i(\Omega))$$

## 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  $S = T \setminus B$ :

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




Сглаживание для выделения релевантных тем  
с помощью словаря «затравочных» ключевых слов



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


# 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  $\ell$ :

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

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  $S_{gg'}$ :


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

## Регуляризаторы для учёта дополнительной информации



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


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



Связи сочетаемости слов ( $n_{uv}$  — частота битерма):

$$R(\Phi) = \tau \sum_{u \in W} \sum_{v \in W} n_{uv} \ln \sum_{t \in T} n_t \phi_{ut} \phi_{vt}$$


relational



Связи или ссылки между документами:

$$R(\Theta) = \tau \sum_{d, c \in D} n_{dc} \sum_{t \in T} \theta_{td} \theta_{tc}$$

hierarchy



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

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

## Модульный подход к синтезу моделей с заданными свойствами

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

Этапы моделирования	Bayesian TM	ARTM
Формализация:	Анализ требований	Анализ требований
Алгоритмизация:	Вероятностная модель порождения данных	Стандартные критерии Свои критерии
Реализация:	Байесовский вывод для данной порождающей модели (VI, GS, EP)	Единый регуляризованный EM-алгоритм для любых моделей и их композиций
Оценивание:	Исследовательский код (Matlab, Python, R)	Промышленный код BigARTM (C++, Python API)

-- нестандартизуемые этапы, уникальная разработка для каждой задачи

-- стандартизуемые этапы

# BigARTM: библиотека тематического моделирования

## Ключевые возможности:

- Большие данные: коллекция не хранится в памяти
- Онлайновый параллельный мультимодальный ARTM
- Встроенная библиотека регуляризаторов и метрик 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 возможности библиотек BigARTM и TopicNet

### BigARTM

- библиотека регуляризаторов
- мультимодальные модели
- иерархические модели
- гиперграфовые модели
- модели связности текста



### TopicNet

- Перебор сценариев регуляризации для выбора моделей
- Автоматическое протоколирование экспериментов
- Построение «банка тем» из множества моделей
- Визуализация результатов тематического моделирования

V.Bulatov, E.Egorov, E.Veselova, D.Polyudova, V.Alekseev, A.Goncharov, K.Vorontsov.  
TopicNet: making additive regularisation for topic modelling accessible. LREC-2020

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

3.7М статей Википедии, 100К слов: время min (перплексия)

проц.	$ T $	Gensim	Vowpal Wabbit	BigARTM	BigARTM асинхрон
1	50	142m (4945)	50m (5413)	42m (5117)	25m (5131)
1	100	287m (3969)	91m (4592)	52m (4093)	32m (4133)
1	200	637m (3241)	154m (3960)	83m (3347)	53m (3362)
2	50	89m (5056)		22m (5092)	13m (5160)
2	100	143m (4012)		29m (4107)	19m (4144)
2	200	325m (3297)		47m (3347)	28m (3380)
4	50	88m (5311)		12m (5216)	7m (5353)
4	100	104m (4338)		16m (4233)	10m (4357)
4	200	315m (3583)		26m (3520)	16m (3634)
8	50	88m (6344)		8m (5648)	5m (6220)
8	100	107m (5380)		10m (4660)	6m (5119)
8	200	288m (4263)		15m (3929)	10m (4309)

D.Kochedykov, M.Apishev, L.Golitsyn, K.Vorontsov.

Fast and Modular Regularized Topic Modelling. FRUCT ISMW, 2017.

## Транзакционные данные

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

- **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  $g$
- **Данные о пассажирских авиаперелётах:**  
 $(u, a, b, c)$  — перелёт клиента  $u$  из  $a$  в  $b$  авиакомпанией  $c$

**Задача:** по наблюдаемой выборке рёбер гиперграфа найти латентные тематические векторные представления его вершин.

## Гиперграфовая транзакционная ARTM

$n_{kdx}$  — частота транзакции  $(d, x)$ ,  $x \subset W$  типа  $k$  в выборке  $E_k$

Максимизация суммы log-правдоподобий с регуляризацией:

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

EM-алгоритм: метод простой итерации для системы уравнений

$$\left\{ \begin{array}{l} \text{E-шаг: } p_{tdx} = \text{norm} \left( \theta_{td} \prod_{v \in x} \phi_{vt} \right) \\ \text{M-шаг: } \begin{cases} \phi_{vt} = \text{norm} \left( \sum_{k \in K} \tau_k \sum_{(d,x) \in E_k} [v \in x] n_{kdx} p_{tdx} + \phi_{vt} \frac{\partial R}{\partial \phi_{vt}} \right) \\ \theta_{td} = \text{norm} \left( \sum_{k \in K} \tau_k \sum_{(d,x) \in E_k} n_{kdx} p_{tdx} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{cases} \end{array} \right.$$

K. Vorontsov. Rethinking probabilistic topic modeling from the point of view of classical non-Bayesian regularization // Springer Optimization and Its Applications. 2023

## Транзакционные данные в рекомендательных системах

$U$  — конечное множество (словарь) клиентов (users)

$I$  — конечное множество (словарь) объектов (items)

$A$  — словарь атрибутов клиентов (соцдем, регион, хобби...)

$B$  — словарь свойств объектов (слова в текстовых объектах)

$C$  — словарь ситуативных контекстов

$J$  — словарь интервалов времени

### Возможные виды данных:

$n_{ui}$  — клиент  $u$  выбрал объект  $i$

$n_{ua}$  — клиент  $u$  имеет атрибут  $a$


$n_{ib}$  — объект  $i$  имеет свойство  $b$

$n_{uv}$  — клиент  $u$  доверяет клиенту  $v$

$n_{uib}$  — клиент  $u$  отметил  $i$  тэгом  $b$

$n_{uic}$  — клиент  $u$  выбрал  $i$  в контексте  $c$

$n_{uicj}$  —  $u$  выбрал  $i$  в  $c$  в интервале  $j$



## Мультимодальная (гипер)графовая тематическая модель

**Общая идея** графовых эмбедингов и тематических моделей:  
наблюдаемые рёбра объясняются скрытыми векторами вершин

$$\begin{aligned} & \sum_{u,i} n_{ui} \ln \sum_{t \in T} p(t|u) p(t|i) p^{-1}(t) \\ & + \tau_1 \sum_{i,b} n_{ib} \ln \sum_{t \in T} p(t|i) p(t|b) p^{-1}(t) \\ & + \tau_2 \sum_{u,a} n_{ua} \ln \sum_{t \in T} p(t|u) p(t|a) p^{-1}(t) \\ & + \tau_3 \sum_{u,i,c} n_{uic} \ln \sum_{t \in T} p(t|i) p(t|u) p(t|c) p^{-2}(t) \\ & + \tau_4 \sum_{u,i,c,t} n_{uic\tau} \ln \sum_{t \in T} p(t|i) p(t|u) p(t|c) p(t|\tau) p^{-3}(t) \rightarrow \max \end{aligned}$$


Оптимизация по всем эмбедингам — векторам вида  $p(t|\bullet)$

Для вероятностных тематических эмбедингов — EM-алгоритм

Для обычных эмбедингов — стохастический градиент

# Обучаемая векторизация данных — глобальный тренд AI/ML

## Foundation Models — гомогенизация векторных представлений



R.Bommasani et al. (Center for Research on Foundation Models, Stanford University)  
On the opportunities and risks of foundation models // CoRR, 20 August 2021.

## Гиперграфовые тематические модели языка

Гипер-ребрами могут быть *сигментоиды* — подмножества термов, связанные по смыслу и порождаемые общей темой:




- предложение / фраза / синтагма
- ветка синтаксического дерева / именная группа
- факт «объект, субъект, действие»
- пары синонимов, гипоним–гипероним, мероним–холоним
- лексическая цепочка
- текст комментария, дата–время, автор

Модель даёт интерпретируемые тематические эмбединги:

- $p(t|d)$  — каждого контейнера, в частности, документа
- $p(t|w) = \phi_{wt} \frac{p(t)}{p(w)}$  — каждого терма, в частности, слова
- $p(t|d, x)$  — каждой отдельной транзакции (фразы, факта)

## Мотивации. Что хотим:

- вместо «мешка слов» — последовательность  $w_1, \dots, w_n$
- вместо документов — локальные контексты слов
- определять тематику любого фрагмента текста
- быстро находить фрагменты, относящиеся к данной теме
- в том числе фразы для суммаризации документа или темы
- разделять документ на тематически однородные сегменты
- визуализировать тематическую структуру документа



## Идея тематизации текста за один проход

Дано:  $s$  — фрагмент текста  $d$ ,  $\Phi$  — тематическая модель

Найти:  $p(t|s)$  — тематический вектор фрагмента текста

### Проблемы:

- как не переобучить вектор  $p(t|s)$ , если текст короткий?
- как согласовать  $p(t|s)$  с объемлющим контекстом  $p(t|d)$ ?
- как согласовать  $p(t|s)$  с  $p(t|w) = \phi_{wt} \frac{p(t)}{p(w)}$  термов  $w \in s$ ?

### Наводящие соображения:

- первая итерация EM-алгоритма с инициализацией  $\theta_{td}^0 = \frac{1}{|T|}$ :

$$\theta_{td}(\Phi) = \text{norm} \left( \sum_{w \in W} n_{dw} p_{tdw} \right) = \sum_{w \in d} \frac{n_{dw}}{n_d} \text{norm} \left( \phi_{wt} \theta_{td}^0 \right)$$

- формула полной вероятности + гипотеза усл. независ.:

$$\theta_{td}(\Phi) = \sum_{w \in d} p(w|d) p(t|w) \cancel{p(t|d)} = \sum_{w \in d} \frac{n_{dw}}{n_d} \text{norm} \left( \phi_{wt} \cancel{p_t} \right)$$

## EM-алгоритм для ARTM с явным выражением $\Theta$ через $\Phi$

Максимизация логарифма правдоподобия:

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

EM-алгоритм: метод простой итерации для системы уравнений

$$p_{tdw} \equiv p(t|d, w) = \text{norm}_{t \in T}(\phi_{wt} \theta_{td}); \quad n_{td} = \sum_{w \in d} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}}$$

$$p'_{tdw} = p_{tdw} + \frac{1}{n_{dw}} \sum_{s \in T} \frac{n_{sd}}{\theta_{sd}} \phi_{wt} \frac{\partial \theta_{sd}}{\partial \phi_{wt}}$$

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

И.А.Ирхин, В.Г.Булатов, К.В.Воронцов. Аддитивная регуляризация тематических моделей с быстрой векторизацией текста. КиМ, 2020.

## Доказательство (по Лемме о максимизации на симплексах)

Оптимизационная задача М-шага относительно  $\Phi$  и  $\Theta(\Phi)$ :

$$Q(\Phi) = \sum_{d \in D} \sum_{u \in W} \sum_{s \in T} n_{du} p_{sdu} \ln(\phi_{us} \theta_{sd}(\Phi)) + R(\Phi, \Theta(\Phi)) \rightarrow \max_{\Phi}$$

Применим Лемму к регуляризованному log-правдоподобию  $Q$ :

$$\begin{aligned} \phi_{wt} \frac{\partial Q}{\partial \phi_{wt}} &= \sum_{d \in D} n_{dw} p_{tdw} + \sum_{d, s, u} n_{du} p_{sdu} \frac{\phi_{wt}}{\theta_{sd}} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} + \phi_{wt} \sum_{d, s} \frac{\partial R}{\partial \theta_{sd}} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} = \\ &= \sum_{d \in D} n_{dw} \left( p_{tdw} + \frac{1}{n_{dw}} \sum_{s \in T} \frac{\phi_{wt}}{\theta_{sd}} \underbrace{\left( \sum_{u \in d} n_{du} p_{sdu} + \theta_{sd} \frac{\partial R}{\partial \theta_{sd}} \right)}_{n_{sd}} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} \right) + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} = \\ &= \sum_{d \in D} n_{dw} \underbrace{\left( p_{tdw} + \frac{1}{n_{dw}} \sum_{s \in T} \frac{n_{sd}}{\theta_{sd}} \phi_{wt} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} \right)}_{p'_{tdw}} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}}. \end{aligned}$$

■

## EM-алгоритм для ARTM с линейной тематизацией документов

$$\theta_{td}(\Phi) = \sum_{w \in d} \frac{n_{dw}}{n_d} \underset{t \in T}{\text{norm}}(\phi_{wt} p_t) \Rightarrow \phi_{wt} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} = \frac{n_{dw}}{n_d} \phi'_{tw} (\delta_{st} - \phi'_{sw})$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\phi'_{tw} \equiv p(t|w) = \underset{t \in T}{\text{norm}}(\phi_{wt} n_t); \quad \theta_{td} = \sum_{w \in d} \frac{n_{dw}}{n_d} \phi'_{tw}$$

$$p_{tdw} \equiv p(t|d, w) = \underset{t \in T}{\text{norm}}(\phi_{wt} \theta_{td}); \quad n_t = \sum_{d \in D} \sum_{w \in d} n_{dw} p_{tdw}$$

$$n_{td} = \sum_{w \in d} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}}$$


$$p'_{tdw} = p_{tdw} + \frac{\phi'_{tw}}{n_d} \left( \frac{n_{td}}{\theta_{td}} - \sum_{s \in T} \phi'_{sw} \frac{n_{sd}}{\theta_{sd}} \right)$$

$$\phi_{wt} = \underset{w \in W}{\text{norm}} \left( \sum_{d \in D} n_{dw} p'_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)$$

## Эксперимент. Проверка модифицированного EM-алгоритма

Коллекция NIPS,  $|T| = 50$ , модели:

- TARTM ( $\Theta$ less ARTM) — модифицированный EM-алгоритм
- naive TARTM — одна итерация обычного EM-алгоритма



- TARTM очищает темы от общеупотребительных слов,
- улучшает разреженность, различность и когерентность тем

И.А.Ирхин, В.Г.Булатов, К.В.Воронцов. Аддитивная регуляризация тематических моделей с быстрой векторизацией текста, 2020.

[https://github.com/ilirhin/python\\_artm](https://github.com/ilirhin/python_artm)

## Упрощение EM-алгоритма для линейной тематизации

- Нет регуляризации по  $\Theta$ , следовательно,  $\frac{\partial R}{\partial \theta_{td}} = 0$
- Значение отношения  $\frac{n_{td}}{\theta_{td}} \approx n_d$  не зависит от  $t$ , подстановка в формулу M-шага приводит к упрощению:  $p'_{tdw} = p_{tdw}$

EM-алгоритм: метод простой итерации для системы уравнений

$$\phi'_{tw} = \underset{t \in T}{\text{norm}}(\phi_{wt} n_t); \quad \theta_{td} = \sum_{w \in d} \frac{n_{dw}}{n_d} \phi'_{tw};$$

$$p_{tdw} = \underset{t \in T}{\text{norm}}(\phi_{wt} \theta_{td}); \quad n_t = \sum_{d \in D} \sum_{w \in d} n_{dw} p_{tdw};$$

$$\phi_{wt} = \underset{w \in W}{\text{norm}} \left( \sum_{d \in D} n_{dw} p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right).$$

Это обычный EM-алгоритм, только с однопроходным E-шагом!  
ОГО! И ТАК МОЖНО БЫЛО?!

## Линейная тематизация: от документа к локальным контекстам

Тематизация документа  $d = (w_1, \dots, w_{n_d})$  за один проход:

$$\theta_{td}(\Phi) \equiv p(t|d) = \frac{1}{n_d} \sum_{i=1}^{n_d} p(t|w_i) = \frac{1}{n_d} \sum_{i=1}^{n_d} \phi'_{tw_i}$$

Тематизация локального контекста  $C_i = (\dots, w_i, \dots)$  терма  $w_i$ :

$$\theta_{ti}(\Phi) \equiv p(t|C_i) = \frac{1}{|C_i|} \sum_{u \in C_i} p(t|u) = \frac{1}{|C_i|} \sum_{u \in C_i} \phi'_{tu}$$

Тематизация локального контекста с распределением весов:

$$\theta_{ti}(\Phi) \equiv p(t|C_i) = \sum_{u \in C_i} \phi'_{tu} \alpha(u|i), \quad \sum_{u \in C_i} \alpha(u|i) = 1, \quad \alpha(u|i) \geq 0$$

Локализованная тематическая модель:

$$p(w|C_i) = \sum_{t \in T} p(w|t) p(t|C_i) = \sum_{t \in T} \phi_{wt} \sum_{u \in C_i} \phi'_{tu} \alpha(u|i)$$

## EM-алгоритм с локализованным E-шагом

$w_1, \dots, w_n$  — сквозная нумерация термов во всей коллекции

$C_i$  — локальный контекст (окружение) терма  $w_i$

$\alpha(u|i)$  — распределение важности термов  $u \in C_i$  для терма  $w_i$

- не нужна гипотеза «мешка слов»
- не нужно разбиение коллекции на документы

EM-алгоритм: метод простой итерации для системы уравнений

$$\phi'_{tw} \equiv p(t|w) = \text{norm}_{t \in T}(\phi_{wt} p_t); \quad \theta_{ti} \equiv p(t|C_i) = \sum_{u \in C_i} \phi'_{tu} \alpha(u|i);$$

$$p_{ti} \equiv p(t|C_i, w_i) = \text{norm}_{t \in T}(\phi_{wi} \theta_{ti}); \quad p_t \equiv p(t) = \frac{1}{n} \sum_{i=1}^n p_{ti};$$

$$\phi_{wt} = \text{norm}_{w \in W} \left( \sum_{i=1}^n [w_i = w] p_{ti} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right).$$

## Быстрое вычисление двунаправленных векторов контекста

Два прохода по тексту — «слева направо» и «справа налево» для вычисления экспоненциальных скользящих средних (ЭСС):

$$\vec{p}(t|i) = \vec{\gamma}_i p(t|w_i) + (1 - \vec{\gamma}_i) \vec{p}(t|i-1), \quad i = 1, \dots, n, \quad \vec{\gamma}_1 = 1$$

$$\bar{p}(t|i) = \bar{\gamma}_i p(t|w_i) + (1 - \bar{\gamma}_i) \bar{p}(t|i+1), \quad i = n, \dots, 1, \quad \bar{\gamma}_n = 1$$


где  $\vec{\gamma}_i$ ,  $\bar{\gamma}_i$  — коэффициенты сглаживания в позиции  $i$

**Основное свойство:** если  $\gamma_i = \gamma$ , то  $\alpha(w_k|i) = \gamma(1 - \gamma)^{|i-k|}$

**Несколько соображений**, как распоряжаться выбором  $\vec{\gamma}_i$ ,  $\bar{\gamma}_i$ :

- $\gamma_i \approx \frac{1}{h}$ , где  $h$  — ширина окна, размер контекста
- $\gamma_i = 1$ , если надо забыть контекст, сменить документ
- $\gamma_i = 0$ , если надо проигнорировать терм
- $\gamma_i$  можно умножать на оценку важности терма

## Использование двунаправленных векторов контекста



Через *дву направленные тематические векторы* определяется:

- $\vec{p}(t|i)$  — тематика левого контекста терма  $w_i$ ;
- $\bar{p}(t|i)$  — тематика правого контекста терма  $w_i$ ;
- $\frac{1}{2}(\vec{p}(t|i) + \bar{p}(t|i))$  — тематика двустороннего контекста  $w_i$ ;
- $p(t|i \dots j) = \frac{1}{2}(\bar{p}(t|i) + \vec{p}(t|j))$  — тематика сегмента  $[i \dots j]$
- $\bar{p}(t|i) \approx \vec{p}(t|j)$  — однородность тематики сегмента  $[i \dots j]$
- $\max_i \|\vec{p}(t|i) - \bar{p}(t|i)\|$  — граница  $i$  между сегментами
- при различных  $\gamma_i$  — короткие и длинные контексты

**Гипотеза:** есть аналогия с моделью внимания и трансформером

## Онлайновый EM-алгоритм с локализованным E-шагом

**Вход:** коллекция, число тем  $|T|$ , параметры  $\beta, \vec{\gamma}_i, \tilde{\gamma}_i, \alpha, \delta$ ;

**Выход:** матрица  $\Phi$ , векторы термов документов  $p_{ti}$ ;

инициализация:  $n_{wt} := 0; \tilde{n}_{wt} := 0; n_t := 1; \phi_{wt} := \text{random};$

**для всех** документов  $d \in D$

$$p_{ti} := \text{norm}_t(\phi_{w_i t} n_t), \quad i = 1, \dots, n_d, \quad t \in T;$$

$$\vec{\theta}_{ti} := \vec{\gamma}_i p_{ti} + (1 - \vec{\gamma}_i) \vec{\theta}_{t,i-1}, \quad i = 1, \dots, n_d, \quad \vec{\gamma}_1 = 1, \quad t \in T;$$

$$\hat{\theta}_{ti} := \tilde{\gamma}_i p_{ti} + (1 - \tilde{\gamma}_i) \hat{\theta}_{t,i+1}, \quad i = n_d, \dots, 1, \quad \tilde{\gamma}_{n_d} = 1, \quad t \in T;$$

$$p_{ti} := \text{norm}_t(\phi_{w_i t} (\beta \vec{\theta}_{ti} + (1 - \beta) \hat{\theta}_{ti})), \quad i = 1, \dots, n_d, \quad t \in T;$$

$$\tilde{n}_{w_i t} := \tilde{n}_{w_i t} + p_{ti}; \quad n_t := n_t + p_{ti}, \quad i = 1, \dots, n_d, \quad t \in T;$$

**если** пора обновить матрицу  $\Phi$  **то**

$$n_{wt} := \delta n_{wt} + \alpha \tilde{n}_{wt}; \quad \tilde{n}_{wt} := 0;$$

$$\phi_{wt} := \underset{w \in W}{\text{norm}} \left( n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right);$$

## Модель внимания Query–Key–Value

$q$  — вектор-запрос, трансформируемый в контекстный вектор  $z$ .

Контекст задаётся последовательностью  $n$  пар ключ-значение:

$K = (k_1, \dots, k_n)$  — векторы-ключи,

$V = (v_1, \dots, v_n)$  — векторы-значения.

Модель внимания — это выпуклая комбинация векторов  $v_i$ ,  
взвешенных по сходству их ключей  $k_i$  с запросом  $q$ :

$$z = \text{Attn}(q, K, V) = \sum_{i=1}^n v_i \text{SoftMax}_i \langle k_i, q \rangle$$

Модель само-внимания (self-attention) трансформирует

$X = (x_1, \dots, x_n)$  — входные бесконтекстные векторы в

$Z = (z_1, \dots, z_n)$  — выходные контекстные векторы:

$$z_i = \text{Attn}(W_q x_i, W_k X, W_v X),$$

где  $W_q, W_k, W_v$  — обучаемые матрицы параметров.

---

Vaswani et al. Attention is all you need. 2017.

## Аналогия локализованного Е-шага с моделью само-внимания

Контекстный тематический вектор на выходе Е-шага:

$$p(t|C_i, w_i) \equiv p_{ti} = \text{norm}_{t \in T}(\phi_{w_i t} \theta_{ti}) = \text{norm}_{t \in T}\left(\sum_{u \in C_i} \phi'_{tu} \phi_{w_i t} \alpha(u|i)\right)$$

Контекстный вектор на выходе модели само-внимания:

$$z_i = \sum_{u \in C_i} W_v x_u \alpha(u|i) = \sum_{u \in C_i} W_v x_u \text{SoftMax}_{u \in C_i} \langle W_q x_i, W_k x_u \rangle$$

### Сходство:

- вектор терма  $w_i$  трансформируется в контекстный вектор
- путём усреднения векторов  $\phi'_u$  из контекста терма  $w_i$ ,
- наиболее (семантически) схожих с вектором терма  $w_i$ .

### Отличия:

- адамарово умножение вектора  $\phi'_u$  на вектор-фильтр  $\phi_{w_i}$ ;
- нет обучаемых матриц  $W_q$ ,  $W_k$ ,  $W_v$  как у модели внимания;
- проецирование итогового вектора на единичный симплекс.

## Аналогия локализованного Е-шага с моделью трансформера

Один проход документа аналогичен модели внимания:

- для каждого  $d \in D$ , для каждой позиции  $i = 1, \dots, n_d$  вычисляются 5 тематических векторов, связанных с термом  $w_i$ :

$\phi'_{tw_i} = \text{norm}_t(\phi_{w_i t} p_t)$  — бесконтекстный вектор терма  $p(t|w_i)$

$\vec{p}(t|i) = \vec{\theta}_{ti}$ ,  $\check{p}(t|i) = \check{\theta}_{ti}$  — векторы левого и правого контекста

$\theta_{ti} = \beta \vec{\theta}_{ti} + (1 - \beta) \check{\theta}_{ti}$  — вектор двустороннего контекста

$p_{ti} = \text{norm}_t(\phi_{w_i t} \theta_{ti})$  — контекстный вектор терма  $p(t|C_i, w_i)$


Несколько таких проходов аналогичны трансформеру:

контекстный вектор терма  $p_{ti} = p(t|C_i, w_i)$  с предыдущего прохода используется вместо его бесконтекстного вектора  $\phi'_{tw_i} = p(t|w_i)$

$L$  таких итераций аналогичны проходу  $L$  блоков внимания

## Первые эксперименты с реализацией Context-ARTM

Коллекция «20 Newsgroups»:  $|D| = 18846$ ,  $|W| = 107672$ .



— улучшилась перплексия, разреженность  $\Phi$ , различность тем

model	time@10 topics	time@30 topics	time@70 topics	time@100 topics
CARTM@CPU	4min 55s $\pm$ 1.7s	9min 20s $\pm$ 9.52s	20min 37s $\pm$ 2.36s	25min 52s $\pm$ 4.63s
BigARTM	1min 30s $\pm$ 1.6s	3min 5s $\pm$ 1.98s	4min 55s $\pm$ 653ms	6min 22s $\pm$ 5.81s

— время хуже в несколько раз, при этом реализация CARTM на Python/JAX, тогда как ядро BigARTM на C++

## В сухом остатке: что сделано, и что дальше

- Теория ARTM — оптимизация без байесовского обучения
- Оптимизация на симплексах уже реализована в pyTorch
- Гиперграфовая модель транзакционных данных
- Предельно упрощённая тематическая модель внимания
- Как параметризовать тематическую модель внимания?
- Будет ли полезен тематический трансформер?
- Не выделить ли вероятностную интерпретируемую часть эмбедингов в нейросетевых языковых моделях?

---

Vorontsov K. V. Rethinking Probabilistic Topic Modeling from the Point of View of Classical Non-Bayesian Regularization. 2023.

Воронцов К.В. Вероятностное тематическое моделирование: теория регуляризации ARTM и библиотека с открытым кодом BigARTM. 2025  
<http://www.machinelearning.ru/wiki/images/d/d5/Voron17survey-artm.pdf>

Rob Churchill, Lisa Singh. The Evolution of Topic Modeling. November, 2022

He Zhao, Dinh Phung, Viet Huynh, Yuan Jin, Lan Du, Wray Buntine. Topic modelling meets deep neural networks: A survey. 2021