

Вероятностные тематические модели

Лекция 4. Аддитивная регуляризация тематических моделей

К. В. Воронцов
vokov@forecsys.ru

Этот курс доступен на странице вики-ресурса
<http://www.MachineLearning.ru/wiki>

«Вероятностные тематические модели (курс лекций, К.В.Воронцов)»

ВМК МГУ • весна 2016

1 Теория ARTM

- EM-алгоритм для ARTM
- Мультимодальные тематические модели
- Рациональный и онлайновый EM-алгоритм для ARTM

2 Использование BigARTM

- Обзор возможностей BigARTM
- Первые шаги
- Как построить свою модель

3 Задания по спецкурсу

- Эксперименты по онлайновому алгоритму
- Эксперименты по тематической сегментации
- Эксперименты по аннотированию и поиску

Напоминание. Задача тематического моделирования

Дано: W — словарь терминов (слов или словосочетаний),

D — коллекция текстовых документов $d \subset W$,

n_{dw} — сколько раз термин w встретился в документе d .

Найти: модель $p(w|d) = \sum_{t \in T} \phi_{wt} \theta_{td}$ с параметрами $\Phi_{W \times T}$ и $\Theta_{T \times D}$:

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

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

Критерий максимума логарифма правдоподобия:

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

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

Проблема: задача стохастического матричного разложения некорректно поставлена: $\Phi \Theta = (\Phi S)(S^{-1} \Theta) = \Phi' \Theta'$.

ARTM – Аддитивная Регуляризация Тематических Моделей

Максимизация \ln правдоподобия с регуляризатором R :

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

ЕМ-алгоритм: метод простой итерации для системы уравнений

Е-шаг: $p_{tdw} = \text{norm}_{t \in T}(\phi_{wt} \theta_{td})$

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

PLSA: $R(\Phi, \Theta) = 0$

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

Условия невырожденности решения

Решение может быть вырожденным для некоторых тем (столбцов матриц Φ) и документов (столбцов матрицы Θ).

Тема t невырождена, если хотя бы для одного термина $w \in W$

$$n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} > 0.$$

Если тема t вырождена, то $p(w|t) = \phi_{wt} \equiv 0$, это означает, что тема исключается из модели (происходит отбор тем).

Документ d невырожден, если хотя бы для одной темы $t \in T$

$$n_{td} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} > 0.$$

Если документ d вырожден, то $p(t|d) = \theta_{td} \equiv 0$, это означает, что модель не в состоянии описать данный документ.

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 μ_i , $i = 1, \dots, m$, λ_j , $j = 1, \dots, k$:

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

Вывод системы уравнений из условий Каруша–Куна–Таккера

- Условия ККТ для ϕ_{wt} (для θ_{td} всё аналогично):

$$\sum_d n_{dw} \frac{\theta_{td}}{p(w|d)} + \frac{\partial R}{\partial \phi_{wt}} = \lambda_t - \mu_{wt}; \quad \mu_{wt} \geq 0; \quad \mu_{wt} \phi_{wt} = 0.$$

- Умножим обе части равенства на ϕ_{wt} и выделим p_{tdw} :

$$\phi_{wt} \lambda_t = \sum_d n_{dw} \frac{\phi_{wt} \theta_{td}}{p(w|d)} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} = n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}}.$$

- Если $\lambda_t \leq 0$, то тема t вырождена, $\phi_{wt} \equiv 0$ для всех w .
- Если $\lambda_t > 0$, то либо $\phi_{wt} = 0$, либо $n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} > 0$:

$$\phi_{wt} \lambda_t = \left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)_+.$$

- Суммируем обе части равенства по $w \in W$:

$$\lambda_t = \sum_{w \in W} \left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)_+.$$

- Подставим λ_t из (5) в (4), получим требуемое. ■

Комбинирование регуляризаторов

Максимизация \ln правдоподобия с k регуляризаторами R_i :

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


где τ_i — коэффициенты регуляризации.

ЕМ-алгоритм: метод простой итерации для системы уравнений

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


Мультиомодальная тематическая модель

находит тематику документов $p(t|d)$, терминов $p(t|w), \dots$




Мультиомодальная тематическая модель

находит тематику документов $p(t|d)$, терминов $p(t|w)$, авторов $p(t|a)$, времени $p(t|t)$, ...




Мультиомодальная тематическая модель

находит тематику документов $p(t|d)$, терминов $p(t|w)$, авторов $p(t|a)$, времени $p(t|t)$, элементов изображений $p(t|e)$, ...




Мультимодальная тематическая модель

находит тематику документов $p(t|d)$, терминов $p(t|w)$, авторов $p(t|a)$, времени $p(t|a)$, элементов изображений $p(t|e)$, ссылок $p(d'|r), \dots$




Мультимодальная тематическая модель

находит тематику документов $p(t|d)$, терминов $p(t|w)$, авторов $p(t|a)$, времени $p(t|a)$, элементов изображений $p(t|e)$, ссылок $p(d'|r)$, баннеров $p(t|b), \dots$




Мультимодальная тематическая модель

находит тематику документов $p(t|d)$, терминов $p(t|w)$, авторов $p(t|a)$, времени $p(t|a)$, элементов изображений $p(t|e)$, ссылок $p(d'|r)$, баннеров $p(t|b)$, пользователей $p(t|u), \dots$



Мультимодальная тематическая модель

Каждая модальность $m \in M$ описывается своим словарём W^m ,
документы могут содержать токены разных модальностей,
каждая тема имеет своё распределение $p(w|t)$, $w \in W^m$



Мультимодальная ARTM

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

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

Максимизация суммы ln правдоподобий с регуляризацией:

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

ЕМ-алгоритм: метод простой итерации для системы уравнений

E-шаг: $p_{tdw} = \text{norm}_{t \in T}(\phi_{wt} \theta_{td})$

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

Рациональный (оффлайновый) ЕМ-алгоритм для ARTM

Идея: Е-шаг встраивается внутрь М-шага

Вход: коллекция D , число тем $|T|$, число итераций i_{\max} ;

Выход: матрицы терминов тем Θ и тем документов Φ ;

инициализация ϕ_{wt}, θ_{td} для всех $d \in D, w \in W, t \in T$;

для всех итераций $i = 1, \dots, i_{\max}$

$n_{wt}, n_{td}, n_t, n_d := 0$ для всех $d \in D, w \in W, t \in T$;

для всех документов $d \in D$ и всех слов $w \in d$

$p_{tdw} = \text{norm}_{t \in T}(\phi_{wt}\theta_{td})$ для всех $t \in T$;

$n_{wt}, n_{td}, n_t, n_d += n_{dw}p_{tdw}$ для всех $t \in T$;

$\phi_{wt} := \text{norm}_{w \in W} \left(\sum_{d \in D} n_{dw}p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)$ для всех $w \in W, t \in T$;

$\theta_{td} := \text{norm}_{t \in T} \left(\sum_{w \in d} n_{dw}p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right)$ для всех $d \in D, t \in T$;

Онлайновый параллельный EM-алгоритм для ARTM

Вход: коллекция D , разбитая на пакеты D_b , $b = 1, \dots, B$;
коэффициент затухания $\rho \in [0, 1]$;

Выход: матрица Φ ;

инициализировать ϕ_{wt} для всех $w \in W$, $t \in T$;

$n_{wt} := 0$, $\tilde{n}_{wt} := 0$ для всех $w \in W$, $t \in T$;

для всех пакетов D_b , $b = 1, \dots, B$

$(\tilde{n}_{wt}) := (\tilde{n}_{wt}) + \text{ProcessBatch}(D_b, \Phi)$;

$n_b := \sum_{d \in D_b} n_d$ — длина пакета D_b в словах;

если пора выполнить синхронизацию, **то**

$n_{wt} := (1 - \rho)n_{wt} + \rho \frac{n}{n_b} \tilde{n}_{wt}$ для всех $w \in W$, $t \in T$;

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

$\tilde{n}_{wt} := 0$ для всех $w \in W$, $t \in T$;

Онлайновый параллельный EM-алгоритм для ARTM

ProcessBatch обрабатывает пакет D_b при фиксированной Φ .

Вход: пакет D_b , матрица $\Phi = (\phi_{wt})$;

Выход: матрица (\tilde{n}_{wt}) ;

$\tilde{n}_{wt} := 0$ для всех $w \in W, t \in T$;

для всех $d \in D_b$

инициализировать $\theta_{td} := \frac{1}{|T|}$ для всех $t \in T$;

повторять

$p_{tdw} := \text{norm}_{t \in T}(\phi_{wt}\theta_{td})$ для всех $w \in d, t \in T$;

$\theta_{td} := \text{norm}_{t \in T} \left(\sum_{w \in d} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right)$ для всех $t \in T$;

пока θ_d не сойдётся;

$\tilde{n}_{wt} := \tilde{n}_{wt} + n_{dw} p_{tdw}$ для всех $w \in d, t \in T$;

Основные особенности библиотеки BigARTM

- *Теоретическая основа:* ARTM
- *Открытый код:* <http://bigartm.org>
- *Онлайновый алгоритм:* потоковая обработка данных
- *Параллельная реализация:* одна из самых быстрых
- *Кроссплатформенность:* Windows, Linux, Mac OS
- *Регуляризаторы:* наращиваемая библиотека
- *Функционалы качества:* наращиваемая библиотека
- *Пользовательские API:* C++, Python, ...

Компоненты библиотеки

- **Ядро библиотеки** — параллельная (многопоточная) реализация онлайнового EM-алгоритма
- **Регуляризаторы** — плагины, которые можно добавлять к библиотеке без структурных изменений ядра
- **Функционалы** — плагины, во многом похожи на регуляризаторы
- **Словари** — внешние объекты с различными дополнительными данными о коллекции
- **Парсер** — преобразование входных данных в форматы BigARTM: UCI-BoW, Vowpal Wabbit, plain text.

Регуляризаторы

- Сглаживание/разреживание/частичное обучение Φ
- Сглаживание/разреживание/частичное обучение Θ
- Декорреляция тем в Φ
- Заданное разреживание Φ
- Балансирование классов в Φ
- Повышение когерентности тем в Φ
- Отбор тем в Θ

Функционалы качества

- Перплексия
- Разреженность Φ
- Разреженность Θ
- Характеристики ядер тем (чистота, контрастность)
- Самые вероятные слова
- Срез матрицы Θ
- Число обработанных документов
- Доля фоновых тем в модели

Установка

Инструкция по установке библиотеки можно найти здесь:

<http://bigartm.readthedocs.org/en/stable/installation/index.html>

Все вопросы отправлять сюда (на английском):

bigartm-users@googlegroups.com

Внимание: в инструкциях ошибок нет!

Если что-то не работает, стоит сперва проверить пути к файлам, переменные окружения, разок попробовать перезагрузить компьютер. Больше половины проблем с установкой на этом благополучно разрешаются.

Пример использования библиотеки в простом эксперименте:

<https://github.com/bigartm/>

[bigartm-book/blob/master/BigARTM_example_RU.ipynb](https://github.com/bigartm/bigartm-book/blob/master/BigARTM_example_RU.ipynb)

Подготовка данных

По аналогии с sklearn входные данные — объект `BatchVectorizer`:

```
BatchVectorizer(batches=None,  
                collection_name=None,  
                data_path=' ',  
                data_format='batches',  
                target_folder=' ',  
                batch_size=1000):
```

Какие могут быть входные данные:

➊ готовые пакеты

- `batches` = путь к директории с пакетами

Подготовка данных

Какие могут быть входные данные:

2 мешок слов в формате UCI-Bow

- collection_name = имя коллекции по названию файла,
- data_path = путь к директории с данными,
- target_folder = путь к директории пакетов и словаря,
- data_format = 'bow_uci'

3 текст в формате Vowpal Wabbit

- data_path = путь к директории с данными,
- target_folder = путь к директории пакетов и словаря,
- data_format = 'vowpal_wabbit'

Пример:

```
batch_vectorizer = artm.BatchVectorizer( \
    data_path='', data_format='bow_uci', \
    collection_name='kos', target_folder='kos')
```

Создание модели

```
ARTM(num_processors=0, num_topics=10, \
      topic_names=None, class_ids=None, \
      cache_theta=True, num_document_passes=1)
```

`num_processors` — число потоков-обработчиков
`num_topics` — число тем (вариант попроще)
`topic_names` — список с именами тем (вариант посложнее)
`class_ids` — dict, ключ — имя модальности, значение — вес
`cache_theta` — флаг кэширования Θ
`num_document_passes` — число итераций по документу

Пример:

```
topic_names = ['topic_name_{}'.format(n) for n in xrange(15)]
model = artm.ARTM(num_processors=4, topic_names=topic_names)
```

Словари

Словарь — объект, содержащий информацию о терминах коллекции, их частоты и другие полезные данные.

Случаи использования словаря:

- при инициализации модели;
- в функционалах качества;
- в регуляризаторах.

Словарь собирается по пакетам с документами:

```
model.gather_dictionary( \
    dictionary_name='dictionary', \
    dictionary_path=batch_vectorizer.data_path)
```

Построение модели PLSA

Теперь инициализируем модель, используя собранный словарь:

```
ARTM.initialize(dictionary_name='dictionary')
```

Запустим 10 итераций оффлайн-алгоритма PLSA
на созданных пакетах с документами:

```
model.fit_offline(batch_vectorizer=batch_vectorizer, \
                  num_collection_passes=10)
```

Добавим функционал качества и регуляризатор

Добавим функционал качества «разреженность матрицы Φ »:

```
model_plsa.scores.add( \
    artm.SparsityPhiScore(name='SparsityPhiScore'))
```

и регуляризатор разреживания Θ :

```
model_artm.regularizers.add( \
    artm.SmoothSparseThetaRegularizer(name='SparseTheta', \
        tau=-0.1))
```

Запустим ещё 10 итераций:

```
model.fit_offline(batch_vectorizer=batch_vectorizer, \
    num_collection_passes=10)
```

Посмотрим на финальное значение разреженности:

```
print model.score_tracker['SparsityPhiScore'].last_value
```

Регуляризаторы

У каждого регуляризатора есть свои параметры
(см. док-строки `bigartm/python/artm/regularizers.py`)

Пример: регуляризатор сглаживания/разреживания Φ :

- `name` — имя регуляризатора, строка
- `tau` — коэффициент регуляризации, вещественное число
- `topic_names` — список имён регуляризуемых тем, список строк
- `class_ids` — список имён регуляризуемых модальностей, список строк
- `dictionary_name` — имя словаря, который нужен регуляризатору, строка

Все параметры опциональные, все можно поменять в любой момент между итерациями обучения модели.

Функционалы качества

У каждого функционала есть свои параметры
(см. док-строки `bigartm/python/artm/scores.py`)

Пример: функционал самых вероятных слов в каждой теме:

- `name` — имя функционала, строка
- `topic_names` — список имён оцениваемых тем, список строк
- `class_id` — имя оцениваемой модальности, строка
- `num_tokens` — максимальное число искомых топ-токенов, целое число
- `dictionary_name` — имя словаря, в данном случае с информацией о совместной встречаемости слов для подсчёта когерентности по топ-токенам, строка

Все параметры опциональные, все можно поменять в любой момент между итерациями обучения модели.

Алгоритм обучения

Оффлайн EM-алгоритм:

- ❶ многократное итерирование коллекции
- ❷ однократный проход по документу
- ❸ хранение матрицы Θ
- ❹ обновление Φ в конце каждого прохода по коллекции
- ❺ применяется при обработке небольших коллекций

Онлайн EM-алгоритм:

- ❶ однократный проход по коллекции
- ❷ многократное итерирование документа
- ❸ нет необходимости хранить матрицу Θ
- ❹ обновление Φ через заданное число пакетов
- ❺ применяется при потоковой обработке больших коллекций

Онлайновый алгоритм. Постановка эксперимента

- **Цель эксперимента:** исследовать зависимость качества модели от параметров онлайнового EM-алгоритма
- **Исходные данные:**
 - коллекция сообщений социальной сети VK
 - коллекция статей википедии
 - коллекция статей arXiv.org
- **Параметры эксперимента** (онлайнового алгоритма):
 - $\text{decay_weight} = (1 - \rho)$, ρ — коэффициент затухания
 - $\text{apply_weight} = \rho^{\frac{n}{n_d}}$
 - batch_size — число документов в каждом пакете
 - update_every — через сколько пакетов обновлять Φ
 - $\text{num_document_passes}$ — число итераций каждого документа
- **Представление результатов:**
 - зависимости перплексии и других функционалов качества от параметров эксперимента

Тематическая сегментация. Постановка эксперимента

- **Цель эксперимента:** проверить способность ARTM восстанавливать тематическую сегментацию текста
- **Исходные данные:**
 - коллекция, генерируемая по заданным матрицам Φ , Θ
 - каждый документ — серия монотематичных сегментов
- **Параметры эксперимента:**
 - средняя длина документа \bar{n}_d
 - средняя длина сегмента \bar{n}_s
 - доля фоновых слов (в первом эксперименте 0)
- **Идея:** пост-обработка $p(t|d, w)$ на Е-шаге
- **Представление результатов:**
 - зависимость доли ошибок восстановления $p(t|d, w)$ от параметров эксперимента

Порождающая тематическая модель сегментированного текстов

Процесс порождения документов d , состоящих из сегментов s :

Вход: распределения $\phi_{wt} = p(w|t)$ и $\theta_{td} = p(t|d)$;

длины документов n_d ; средняя длина сегментов m ;

Выход: коллекция документов;

для всех документов $d \in D$

$k_t := \lceil n_d \theta_{td} / m \rceil$ — число сегментов для каждой $t \in T$;

$k := \sum_t k_t$ — суммарное число сегментов всех тем;

$i := 1$ — текущая позиция в порождаемом документе d ;

для всех порождаемых сегментов $j = 1, \dots, k$

выбрать тему сегмента t_j из $p(t|d)$;

выбрать длину сегмента $n_j \approx n_d \theta_{t_j d} / k_{t_j}$;


для всех порождаемых n_j слов

выбрать слово w_i из $p(w|t_j)$; $i++$;

Гипотеза о тематической сегментации текста

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

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



Предположения разреженности и непрерывности тематики:

- текст разбивается на тематически однородные сегменты
- каждый сегмент относится к 1–2 предметным темам
- слова общей лексики не влияют на тематику сегмента
- соседние сегменты часто имеют общие темы

Аннотирование и поиск. Постановка эксперимента

- **Цель эксперимента:** оценить согласованность автоматического аннотирования и тематического поиска
- **Исходные данные:**
 - коллекция статей научных конференций ММРО/ИОИ
 - коллекция статей arXiv.org
- **Параметры эксперимента:**
 - параметры оценки тематической значимости фраз
 - длина аннотации
 - мера тематической близости документов
- **Идея:** согласованность аннотирования и поиска должна означать высокое качество реализации обеих функций
- **Представление результатов:**
 - зависимость качества поиска (номер исходного документа в списке выдачи) от параметров эксперимента

Алгоритм формирования аннотации документа

Документ d — последовательность фраз $s_j, j = 1, \dots, k_d$.

Фраза s — последовательность терминов $w_{si}, i = 1, \dots, n_s$.

Вход: тематическая модель $\phi_{wt} = p(w|t)$ и $\theta_{td} = p(t|d)$;

документ d ; распределение $p(t|d, w_{si})$; бюджет m ;

Выход: аннотация — набор фраз из d суммарной длины $\leq m$;

для всех фраз s документа d

$Q_s := \max_{t \in T} \sum_i p(w_{si}|t)$ — оценка ценности фразы s ;

$p(t|s) := \text{avr}_i p(t|d, w_{si})$ — тематический вектор фразы s ;

найти подмножество фраз $S = \{s_j\}$ такое, что:

$$\left\{ \begin{array}{ll} \sum_s n_s \leq m & \text{— длина в рамках бюджета} \\ \sum_s Q_s \rightarrow \max & \text{— ценность максимальна} \\ \rho(\text{avr}_s p(t|s), p(t|d)) \rightarrow \min & \text{— релевантность максимальна} \end{array} \right.$$

- Задача тематического моделирования некорректно поставлена, её решение не единственно и не устойчиво.
- Регуляризация — стандартный приём решения таких задач.
- Подход ARTM позволяет комбинировать регуляризаторы, строить тематические модели с требуемыми свойствами, иметь общую для всех моделей реализацию.
- Модель LDA — частный случай регуляризатора сглаживания.
- Теория ARTM реализована в проекте BigARTM.
- Регуляризаторы и модальности — в следующих лекциях.