

# Вероятностные тематические модели

## Лекция 5. Регуляризаторы для АРТМ

К. В. Воронцов  
[vokov@forecsys.ru](mailto: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 Сглаживание, разреживание, декоррелирование

- Регуляризаторы сглаживания и разреживания
- Разделение тем на предметные и фоновые
- Регуляризатор для отбора тем

## 2 Эксперименты

- Измерение качества тематической модели
- Композиции регуляризаторов
- Отбор тем

## 3 Регуляризаторы и метрики качества в BigARTM

- Регуляризаторы
- Словари
- Метрики качества

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

## Напоминание. Задача ARTM и регуляризованный EM-алгоритм

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

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

EM-алгоритм: метод простой итерации для системы уравнений

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

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

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


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

## Напоминание. Дивергенция Кульбака–Лейблера


- $KL(P\|Q) \geq 0; \quad KL(P\|Q) = 0 \Leftrightarrow P = Q;$
- Минимизация  $KL$  эквивалентна максимизации правдоподобия:

$$KL(P\|Q(\alpha)) = \sum_{i=1}^n p_i \ln \frac{p_i}{q_i(\alpha)} \rightarrow \min_{\alpha} \Leftrightarrow \sum_{i=1}^n p_i \ln q_i(\alpha) \rightarrow \max_{\alpha}$$


- Если  $KL(P\|Q) < KL(Q\|P)$ , то  $P$  вложено в  $Q$ :



$$KL(P\|Q) = 0.44 \\ KL(Q\|P) = 2.97$$



$$KL(P\|Q) = 0.44 \\ KL(Q\|P) = 0.44$$



$$KL(P\|Q) = 2.97 \\ KL(Q\|P) = 2.97$$

## Регуляризатор сглаживания (переосмысление LDA)

Гипотеза сглаженности:

распределения  $\phi_{wt}$  близки к заданному распределению  $\beta_w$ ;  
распределения  $\theta_{td}$  близки к заданному распределению  $\alpha_t$ .

$$\sum_{t \in T} \text{KL}(\beta_w \| \phi_{wt}) \rightarrow \min_{\Phi}; \quad \sum_{d \in D} \text{KL}(\alpha_t \| \theta_{td}) \rightarrow \min_{\Theta}.$$

Максимизируем сумму регуляризаторов:

$$R(\Phi, \Theta) = \beta_0 \sum_{t \in T} \sum_{w \in W} \beta_w \ln \phi_{wt} + \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_t \ln \theta_{td} \rightarrow \max.$$

Подставляем, получаем формулы M-шага LDA:

$$\phi_{wt} = \underset{w \in W}{\text{norm}}(n_{wt} + \beta_0 \beta_w), \quad \theta_{td} = \underset{t \in T}{\text{norm}}(n_{td} + \alpha_0 \alpha_t).$$

---

Этого вы не найдёте в D.Blei, A.Ng, M.Jordan. Latent Dirichlet allocation // Journal of Machine Learning Research, 2003. — Vol. 3. — Pp. 993–1022.

## Регуляризатор разреживания (обобщение LDA)

**Гипотеза разреженности:** среди  $\phi_{wt}, \theta_{td}$  много нулей;  
распределения  $\phi_{wt}$  **далеки** от заданного распределения  $\beta_w$ ;  
распределения  $\theta_{td}$  **далеки** от заданного распределения  $\alpha_t$ .

$$\sum_{t \in T} \text{KL}(\beta_w \| \phi_{wt}) \rightarrow \max_{\Phi}; \quad \sum_{d \in D} \text{KL}(\alpha_t \| \theta_{td}) \rightarrow \max_{\Theta}.$$

Максимизируем сумму регуляризаторов:

$$R(\Phi, \Theta) = -\beta_0 \sum_{t \in T} \sum_{w \in W} \beta_w \ln \phi_{wt} - \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_t \ln \theta_{td} \rightarrow \max.$$

Подставляем, получаем **«анти-LDA»**:

$$\phi_{wt} = \underset{w \in W}{\text{norm}}(n_{wt} - \beta_0 \beta_w), \quad \theta_{td} = \underset{t \in T}{\text{norm}}(n_{td} - \alpha_0 \alpha_t).$$

---

Varadarajan J., Emonet R., Odobez J.-M. A sparsity constraint for topic models — application to temporal activity mining // NIPS-2010.

## Объединение сглаживания и разреживания

Общий вид регуляризаторов сглаживания и разреживания:

$$R(\Phi, \Theta) = \beta_0 \sum_{t \in T} \sum_{w \in W} \beta_{wt} \ln \phi_{wt} + \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_{td} \ln \theta_{td} \rightarrow \max,$$

где  $\beta_0 > 0$ ,  $\alpha_0 > 0$  — коэффициенты регуляризации,  
 $\beta_{wt}$ ,  $\alpha_{td}$  — параметры, задаваемые пользователем:

- $\beta_{wt} > 0$ ,  $\alpha_{td} > 0$  — сглаживание
- $\beta_{wt} < 0$ ,  $\alpha_{td} < 0$  — разреживание

Частичное обучение (semi-supervised learning) темы  $t$ :

- $\beta_{wt} = [w \in W_t]$  — белый список  $W_t$  терминов темы  $t$
- $\alpha_{td} = [d \in D_t]$  — белый список  $D_t$  документов темы  $t$
- $\beta_{wt} = -[w \in W_t]$  — чёрный список  $W_t$  терминов темы  $t$
- $\alpha_{td} = -[d \in D_t]$  — чёрный список  $D_t$  документов темы  $t$

## Обобщённая KL-дивергенция

KL-дивергенция — это мера сходства векторов  $(\beta_w)$  и  $(\ln \phi_w)$ :

$$R(\Phi, \Theta) = \beta_0 \sum_{t \in T} \sum_{w \in W} \beta_{wt} \ln(\phi_{wt}) + \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_{td} \ln(\theta_{td}) \rightarrow \max,$$

Почему бы не заменить  $\ln$  другой монотонной функцией?

$$R(\Phi, \Theta) = \beta_0 \sum_{t \in T} \sum_{w \in W} \beta_{wt} \mu(\phi_{wt}) + \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_{td} \mu(\theta_{td}) \rightarrow \max.$$

М-шаг для регуляризатора обобщённой KL-дивергенции:

$$\phi_{wt} = \underset{w \in W}{\text{norm}}(n_{wt} + \beta_0 \beta_{wt} f(\phi_{wt})), \quad \theta_{td} = \underset{t \in T}{\text{norm}}(n_{td} + \alpha_0 \alpha_{td} f(\theta_{td})),$$


где  $f(x) = x \mu'(x)$ ; в случае KL-дивергенции  $\mu \equiv \ln$ ,  $f(x) = 1$ .

## Разделение тем на предметные и фоновые


Предметные темы  $S$  содержат термины предметной области,  
 $p(w|t)$ ,  $p(t|d)$ ,  $t \in S$  — разреженные, существенно различные

Фоновые темы  $B$  содержат слова общей лексики,  
 $p(w|t)$ ,  $p(t|d)$ ,  $t \in B$  — существенно отличные от нуля

$\Phi_{W \times T}$



$\Theta_{T \times D}$



## Регуляризатор декоррелирования тем

Цель — выделить лексическое ядро каждой темы, набор терминов, отличающий её от других тем.

Минимизируем ковариации между вектор-столбцами  $\phi_t$ :

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

Подставляем, получаем ещё один вариант разреживания — постепенное контрастирование строк матрицы  $\Phi$ :

$$\phi_{wt} = \underset{w \in W}{\text{norm}} \left( n_{wt} - \tau \phi_{wt} \sum_{s \in T \setminus t} \phi_{ws} \right).$$

---

Tan Y., Ou Z. Topic-weak-correlated latent Dirichlet allocation // 7th Int'l Symp. Chinese Spoken Language Processing (ISCSLP), 2010. — Pp. 224–228.

## Регуляризатор для сокращения числа тем

**Цель:** избавиться от «мелких» незначимых тем. (заодно получается удалить зависимые и расщеплённые темы)

Разреживаем распределение  $p(t) = \sum_d p(d)\theta_{td}$ , максимизируя KL-дивергенцию между  $p(t)$  и равномерным распределением:

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

Подставляем, получаем:

$$\theta_{td} = \text{norm}_{t \in T} \left( n_{td} - \tau \frac{n_d}{n_t} \theta_{td} \right), \text{ вариант: } \theta_{td} = \text{norm}_{t \in T} \left( n_{td} \left( 1 - \frac{\tau}{n_t} \right) \right).$$

**Эффект:** строки матрицы  $\Theta$  целиком обнуляются для тем  $t$ , собравших слишком мало слов по коллекции,  $n_t = \sum_{d,w} n_{dwt}$ .

---

Vorontsov K. V., Potapenko A. A., Plavin A. V. Additive Regularization of Topic Models for Topic Selection and Sparse Factorization // SLDS 2015.

## Некоторые критерии качества тематической модели

Построение ВТМ — многокритериальная оптимизация.

Поэтому критериев для контроля качества модели тоже много.

- Перплексия контрольной коллекции:  $\mathcal{P} = \exp(-\frac{1}{n}\mathcal{L})$
- Разреженность — доля нулевых элементов в  $\Phi$  и  $\Theta$
- Характеристики интерпретируемости тем:
  - когерентность темы: [Newman, 2010]
  - размер ядра темы:  $|W_t|$ , ядро  $W_t = \{w : p(t|w) > 0.25\}$
  - чистота темы:  $\sum_{w \in W_t} p(w|t)$
  - контрастность темы:  $\frac{1}{|W_t|} \sum_{w \in W_t} p(t|w)$
- Вырожденность тематической модели:
  - число тем:  $|T|$
  - доля фона в коллекции:  $\frac{1}{n} \sum_{d,w} \sum_{t \in B} p(t|d, w)$

## Оценки интерпретируемости: когерентность

Когерентность темы  $t$

$$\text{PMI}_t = \frac{2}{k(k-1)} \sum_{i=1}^{k-1} \sum_{j=i}^k \text{PMI}(w_i, w_j)$$

где  $w_i$  —  $i$ -й термин в порядке убывания  $\phi_{wt}$ .

$\text{PMI}(u, v) = \ln \frac{P_{uv}}{P_u P_v}$  — поточечная взаимная информация (pointwise mutual information),

$P_{uv}$  — доля документов, в которых термины  $u, v$  хотя бы один раз встречаются рядом (в окне 10 слов),

$P_u$  — доля документов, в которых  $u$  встретился хотя бы 1 раз.

---

Newman D., Lau J.H., Grieser K., Baldwin T. Automatic evaluation of topic coherence // Human Language Technologies, HLT-2010, Pp. 100–108.

## Разреживание + Сглаживание + Декорреляция + Отбор тем

M-шаг при комбинировании 6 регуляризаторов:


$$\phi_{wt} = \underset{w}{\text{norm}} \left( n_{wt} + \tau_1 \underbrace{\beta_w[t \in B]}_{\substack{\text{сглаживание} \\ \text{фоновых} \\ \text{тем}}} - \tau_2 \underbrace{\beta_w[t \in S]}_{\substack{\text{разреживание} \\ \text{предметных} \\ \text{тем}}} - \tau_3 \phi_{wt} \underbrace{\sum_{s \in S \setminus t} \phi_{ws}}_{\substack{\text{декорреляция}}} \right)$$

$$\theta_{td} = \underset{t}{\text{norm}} \left( n_{td} + \tau_4 \underbrace{\alpha_t[t \in B]}_{\substack{\text{сглаживание} \\ \text{фоновых} \\ \text{тем}}} - \tau_5 \underbrace{\alpha_t[t \in S]}_{\substack{\text{разреживание} \\ \text{предметных} \\ \text{тем}}} - \tau_6 \underbrace{\frac{n_d}{n_t} \theta_{td}}_{\substack{\text{удаление} \\ \text{малых тем}}} \right)$$

**Данные:** статьи NIPS (Neural Information Processing System)  
 $|D| = 1566$  статей,  $n = 2.3$  M,  $|W| = 13$  K,  
 контрольная коллекция:  $|D'| = 174$ .


## Разреживание, сглаживание, декорреляция

Зависимости критериев качества от итераций EM-алгоритма  
(серый — PLSA, чёрный — ARTM)



## Те же регуляризаторы, плюс отбор тем

Зависимости критериев качества от итераций EM-алгоритма  
(серый — PLSA, чёрный — ARTM)



## Выводы

Одновременное улучшение многих критериев качества:

- разреженность тем выросла от 0 до 95%–98%
- когерентность тем выросла от 0.1 до 0.3
- чистота тем выросла от 0.15 до 0.8
- контрастность тем выросла от 0.4 до 0.6
- почти без потери *перплексии* (правдоподобия) модели

Подобраны траектории регуляризации:

- разреживание включать постепенно после 10-20 итераций
- сглаживание включать сразу
- декорреляцию включать сразу и как можно сильнее
- сокращение числа тем включать постепенно,
- никогда не совмещая с декорреляцией на одной итерации

## Эксперименты с регуляризатором отбора тем

Коллекция статей NIPS (Neural Information Processing System)

- $|D| = 1566$  обучающих документов;  $|D'| = 174$  тестовых
- $|W| = 13K$  — мощность словаря

Синтетическая коллекция:

- строим PLSA за 500 итераций,  $|T_0| = 50$  тем на NIPS
- генерируем  $(n_{dw}^0)$  из полученных  $\Phi$  и  $\Theta$ :


$$n_{dw}^0 = n_d \sum_{t \in T} \phi_{wt} \theta_{td}$$

Параметрическое семейство полусинтетических данных:

- $n_{dw}^\alpha$  — смесь синтетических данных  $n_{dw}^0$  и реальных  $n_{dw}$ :

$$n_{dw}^\alpha = \alpha n_{dw} + (1 - \alpha) n_{dw}^0$$


## Попытка определения числа тем



- На синтетических данных надёжно находим  $|T| = 50$ ,
- в широком интервале значений коэффициента  $\tau$ ;
- однако на реальных данных нет столь чёткого интервала.

## Сравнение с байесовской тематической моделью HDP


HDP (Hierarchical Dirichlet Process, Teh et. al, 2006) —  
«state-of-the-art» байесовский подход к определению числа тем



- Коэффициент концентрации  $\gamma$  в HDP влияет на  $|T|$  так же сильно, как выбор коэффициента  $\tau$  в ARTM.

## Сравнение ARTM и HDP по устойчивости


Запуск ARTM и HDP много раз из случайных инициализаций:



- HDP менее устойчив, причём в двух смыслах:
  - число тем сильнее флуктуирует от итерации к итерации;
  - результаты нескольких запусков различаются сильнее.
- «Рекомендуемые» значения параметров  $\gamma$  в HDP и  $\tau$  в ARTM дают примерно равное число тем  $|T| \approx 60$

## Сравнение ARTM и HDP по времени вычислений

Сравнение времени одного прохода коллекции (sec)




- ARTM в 100 раз быстрее!

---

Vorontsov K. V., Potapenko A. A., Plavin A. V. Additive regularization of topic models for topic selection and sparse factorization // SLDS 2015, Royal Holloway, University of London, UK. pp. 193–202.

## Удаление линейно зависимых и расщеплённых тем

Добавили 50 линейных комбинаций тем в модельную  $\Phi$ .  
Расщепили 50 тем, каждую на две подтемы в модельной  $\Phi$ .



- Удаляются линейно зависимые и расщеплённые темы
- Остаются более различные темы исходной модели.

---

Vorontsov K. V., Potapenko A. A., Plavin A. V. Additive regularization of topic models for topic selection and sparse factorization // SLDS 2015, Royal Holloway, University of London, UK. pp. 193–202.

## Список классов регуляризаторов

- `artm.SmoothSparsePhiRegularizer`
  - сглаживание или разреживание  $\Phi$
- `artm.SmoothSparseThetaRegularizer`
  - сглаживание или разреживание  $\Theta$
- `artm.DecorrelatorPhiRegularizer`
  - декоррелятор  $\Phi$
- `artm.SpecifiedSparsePhiRegularizer`
  - разреживание  $\Phi$  с заданной величиной
- `artm.ImproveCoherencePhiRegularizer`
  - повышение когерентности
- `artm.SmoothPtdwRegularizer`
  - сглаживание распределений  $p_{tdw}$
- `artm.TopicSelectionThetaRegularizer`
  - разреживание распределения  $p(t)$  для отбора тем

## Регуляризатор сглаживания/разреживания матрицы $\Phi$

M-шаг для обобщённой KL-дивергенции:

$$\phi_{wt} = \underset{w \in W^m}{\text{norm}}(n_{wt} + \tau \beta_w f(\phi_{wt}))$$

Параметры регуляризатора (все опциональные):

- `name` — имя регуляризатора, строка
- `tau` — коэффициент регуляризации  $\tau$ , вещественное число
- `topic_names` — список имён тем  $t$ , список строк
- `class_ids` — список имён модальностей  $m$ , список строк
- `dictionary_name` — имя словаря значений ( $\beta_w$ ), строка
- `kl_function_info` — функция  $f(x) = x\mu'(x)$ ,  
по умолчанию  $f(x) = 1$  соответствует KL-дивергенции

## Параметры name, tau, kl\_function\_info

Имя регуляризатора используется для его идентификации.

**Пример** создания регуляризатора:

```
model.regularizer.add(artm.SmoothSparsePhiRegularizer(name='SSPR'))  
model.regularizer['SSPR'].tau = -1  
model.regularizer['SSPR'].kl_function_info =\\  
    KlFunctionInfo(function_type='pol', power_value=-1)
```

`kl_function_info`— объект класса `KlFunctionInfo`

В данном случае задана функция  $f(x) = \frac{1}{x}$ , которая приводит к поощрению более редких слов при  $\beta_w > 0$ :

$$\phi_{wt} = \underset{w \in W^m}{\text{norm}} \left( n_{wt} + \tau \beta_w \frac{1}{\phi_{wt}} \right)$$

## Параметры topic\_names и class\_ids

```
model.regularizer['SSPR'].topic_names= ['Тема_1']
```

```
model.regularizer['SSPR'].class_ids= ['@default_class']
```

```
model.regularizer['SSPR'].topic_names= ['Тема_1','Тема_2']
```

```
model.regularizer['SSPR'].class_ids= ['@label_class','@author_class']
```

	Тема 1	Тема 2	...	Тема  T
@default_class				
Слово 1	■			
Слово 2				
...				
Слово  W	■			
	Тема 1	Тема 2	...	Тема  T
@label_class				
Метка класса 1	■			
Метка класса 2	■			
...	■			
Метка класса  C	■			
	Тема 1	Тема 2	...	Тема  T
@author_class				
Имя автора 1	■			
Имя автора 2	■			
...	■			
Имя автора  A	■			



## Регуляризатор сглаживания/разреживания $\Theta$

М-шаг для обобщённой KL-дивергенции:

$$\theta_{td} = \operatorname{norm}_{t \in T}(n_{td} + \tau \alpha_i f(\theta_{td}))$$

Параметры регуляризатора (все опциональные):

- `name` — имя регуляризатора, строка
- `tau` — коэффициент регуляризации  $\tau$ , вещественное число
- `topic_names` — список имён тем, список строк
- `alpha_iter` — массив значений  $(\alpha_i)$ ,  
на каждую  $i$ -ю итерацию по документу, список чисел
- `kl_function_info` — функция  $f(x) = x\mu'(x)$ ,  
по умолчанию  $f(x) = 1$  соответствует KL-дивергенции

## Регуляризатор декорреляции $\Phi$

Формула М-шага для декоррелирования столбцов  $\Phi$ :

$$\phi_{wt} = \underset{w \in W^m}{\text{norm}} \left( n_{wt} - \tau \phi_{wt} \sum_{s \in T \setminus t} \phi_{ws} \right).$$

Повышает различность тем как столбцов матрицы  $\Phi$ .

- `name` — имя регуляризатора, строка
- `tau` — коэффициент регуляризации  $\tau$ , вещественное число
- `topic_names` — список имён тем  $t$ , список строк
- `class_ids` — список имён модальностей  $m$ , список строк

## Параметр `dictionary_name`

Регуляризатор сглаживания/разреживания матрицы  $\Phi$ :

$$\phi_{wt} = \underset{w \in W^m}{\text{norm}}(n_{wt} + \tau \beta_w f(\phi_{wt}))$$

$\beta_w$  позволяет регуляризовать по-разному отдельные слова.  
Значение  $\beta_w$  хранится в словаре, своё для каждого слова.

Библиотека генерирует словарь, в котором

$\beta_w = \frac{n_w}{n}$  — относительная частота слова  $w$  в коллекции.

Словарь можно редактировать и записывать значения  $\beta_w$ ,  
лучше отвечающие поставленной задаче.

Если словарь отсутствует или  $\beta_w$  для слова  $w$  не найдено,  
то используется  $\beta_w = 1$ .

## Работа со словарями

Словарь создаётся по батчам вызовом

```
model.gather_dictionary(dictionary_name, dictionary_path)
```

В этом случае словарь создаётся в ядре библиотеки,  
и к нему можно обращаться по имени `dictionary_name`.

Чтобы не создавать словарь каждый раз заново, его можно  
сохранить на диск, а потом загружать обратно:

```
model.save_dictionary(dictionary_name, dictionary_path)
```

```
model.load_dictionary(dictionary_name, dictionary_path)
```

## Работа со словарями

Словарь можно редактировать вручную: надо выгрузить содержимое в виде текстового файла, редактировать (например, менять  $\beta_w$ ), и загрузить обратно:

```
model.save_text_dictionary(dictionary_name, new_dictionary_path)  
model.load_text_dictionary(new_dictionary_name, new_dictionary_path)
```

Отредактированный файл можно сохранить на диск:

```
model.save_dictionary(new_dictionary_name, new_dictionary_path)
```

**ВАЖНО:** не удаляйте словарь, созданный библиотекой, он полезен для разных метрик (например, перплексии).  
Создавайте новые словари с другими именами.

Количество загружаемых в ядро словарей не ограничено.

## Список классов метрик качества

- `artm.PerplexityScore` — перплексия
- `artm.SparsityPhiScore` — разреженность  $\Phi$
- `artm.SparsityThetaScore` — разреженность  $\Theta$
- `artm.TopicKernelScore` — ядерные слова тем и когерентности
- `artm.TopTokensScore` — топовые слова тем и когерентности
- `artm.TopicMassPhiScore` — «массы»  $n_t$  тем, посчитанные по  $\Phi$

Информационные функции (не метрики качества!)

- `artm.ThetaSnippetScore` — сниппет матрицы  $\Theta$
- `artm.ItemsProcessedScore` — число обработанных документов

## Перплексия

Перплексия коллекции  $D$ :

$$\mathcal{P} = \exp\left(-\frac{1}{n} \sum_{d \in D} \sum_{w \in d} n_{dw} \ln p(w|d)\right), \quad p(w|d) = \sum_{t \in T} \phi_{wt} \theta_{td}$$

- `name` — имя метрики, строка
- `topic_names` — список имён тем, список строк
- `class_ids` — список имён модальностей, список строк
- `dictionary_name` — имя словаря, строка
- `use_unigram_document_model` — флаг использования униграммной модели документа/коллекции

## Перплексия, поправка в случае $p(w|d) = 0$

Перплексия коллекции  $D$ :

$$\mathcal{P} = \exp\left(-\frac{1}{n} \sum_{d \in D} \sum_{w \in d} n_{dw} \ln p(w|d)\right), \quad p(w|d) = \sum_{t \in T} \phi_{wt} \theta_{td}$$

Если  $p(w|d) = 0$ , то используется униграммная модель документа  $p(w|d) = \frac{n_{dw}}{n_d}$  или коллекции  $p(w|d) = \frac{n_w}{n}$ .

Второй вариант лучше, т.к. не занижает перплексию, но он требует словаря значений  $\beta_w$ ,  $w \in W$ .

Поэтому для подсчёта перплексии требуется:

- ❶ загрузить в модель словарь, сгенерированный библиотекой;
- ❷ подключить словарь к метрике через `dictionary_name`;
- ❸ задать `use_unigram_document_model = False`.

## Разреженность $\Phi$ и топ-слова

Параметры метрики разреженности  $\Phi$ :

- `name` — имя метрики, строка
- `topic_names` — список имён тем, список строк
- `class_id` — имя модальности, строка
- `eps` — константа толерантности, число

Параметры метрики топовых (наиболее вероятных) слов  $\Phi$ :

- `name` — имя метрики, строка
- `topic_names` — список имён тем, список строк
- `class_id` — имя модальности, строка
- `num_tokens` — число топовых слов, целое число
- `dictionary_name` — имя словаря, строка

## Пример использования метрик

```
model.scores.add(artm.PerplexityScore(name='PSScore',  
                                         dictionary_name='dictionary'))  
model.scores.add(artm.SparsityPhiScore(name='SPScore'))  
model.scores.add(artm.TopTokensScore(name='TTScore', num_tokens=20))  
model.fit_offline(num_collection_passes=10)  
  
model.score_tracker['SPScore'].value
```

— вернётся список значений на каждой итерации

```
model.score_tracker['SPScore'].last_value  
— вернётся финальное значение
```

```
model.score_tracker['TTScore'].last_topic_info['Тема_1'].tokens  
— вернётся финальный топ-20 слов для «темы 1».
```

```
model.score_tracker['TTScore'].last_topic_info['Тема_1'].weights  
— а так можно посмотреть соответствующие им значения  $\phi_{wt}$ .
```

- Разреживание, сглаживание и декоррелирование — «джентльменский набор» регуляризаторов.
- Регуляризатор отбора тем удаляет зависимые темы. Оптимального числа тем вообще не существует!
- Решение задач анализа текстов в стиле ARTM — это построение моделей с заданными свойствами путём включения нужного набора регуляризаторов.
- Коэффициенты регуляризации пока подбираем вручную, их автоматическая настройка — в стадии разработки.