

# Вероятностные тематические модели

## Лекция 4. 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 2017

## 1 Проблема неустойчивости решения

- Аддитивная регуляризация тематических моделей
- Неустойчивость на синтетических данных
- Неустойчивость на реальных данных

## 2 Сглаживание, разреживание, декоррелирование

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

## 3 Эксперименты

- Измерение качества тематической модели
- Композиции регуляризаторов
- Отбор тем

## 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. ARTM и регуляризованный EM-алгоритм

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

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

EM-алгоритм: метод простой итерации для системы уравнений

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

## Способны ли PLSA и LDA восстановить истинные темы?

Матрицы  $\Phi_0$  и  $\Theta_0$  порождаются распределением Дирихле.  
Синтетическая коллекция порождается матрицами  $\Phi_0$  и  $\Theta_0$ .  
Размеры:  $|D| = 500$ ,  $|W| = 1000$ ,  $|T| = 30$ ,  $n_d \in [100, 600]$ .

Цель — сравнить восстановленные распределения  $p(i|j)$   
с исходными синтетическими распределениями  $p_0(i|j)$   
по среднему расстоянию Хеллингера:

$$H(p, p_0) = \frac{1}{m} \sum_{j=1}^m \sqrt{\frac{1}{2} \sum_{i=1}^n \left( \sqrt{p(i|j)} - \sqrt{p_0(i|j)} \right)^2},$$

как для самих матриц  $\Phi$  и  $\Theta$ , так и для их произведения:


$$D_\Phi = H(\Phi, \Phi_0);$$

$$D_\Theta = H(\Theta, \Theta_0);$$

$$D_{\Phi\Theta} = H(\Phi\Theta, \Phi_0\Theta_0).$$

## Разреженность векторов, порождаемых распределением Dir


Зависимость разреженности (доли почти нулевых элементов) распределений  $\theta_d^0 \sim \text{Dir}(\alpha)$  и  $\phi_t^0 \sim \text{Dir}(\beta)$  от параметров  $\alpha$  и  $\beta$  симметричного распределения Дирихле:




## Неустойчивость восстановления матриц $\Phi$ и $\Theta$

Зависимость точности восстановления матриц  $\Phi$ ,  $\Theta$  и  $\Phi\Theta$  от разреженности матрицы  $\Phi_0$  при фиксированном  $\alpha = 0.01$

PLSA



LDA




Виталий Глушаченков. Устойчивость матричных разложений в задачах тематического моделирования // Магистерская диссертация. МФТИ, 2013.


## Неустойчивость восстановления матриц $\Phi$ и $\Theta$

Зависимость точности восстановления матриц  $\Phi$ ,  $\Theta$  и  $\Phi\Theta$  от разреженности матрицы  $\Theta_0$  при фиксированном  $\beta = 0.1$

PLSA



LDA



Виталий Глушаченков. Устойчивость матричных разложений в задачах тематического моделирования // Магистерская диссертация, МФТИ, 2013.

## Цель эксперимента

Посты ЖЖ:  $|D|=300$  К,  $|W|=154$  К,  $n=35$  М,  $|T|=120$ .

LDA: симметричное распределение Дирихле,  $\beta = 0.1$ ,  $\alpha = 0.5$ .

**Цель эксперимента** — оценить различность тем, получаемых в нескольких запусках алгоритма LDA Gibbs Sampling.

**Проблема «проклятия размерности»:**

длинные хвосты мешают сравнивать распределения.

Доля существенных терминов в темах (word ratio):

$$WR = \frac{1}{|W|} \frac{1}{|T|} \sum_{w \in W} \sum_{t \in T} [\phi_{wt} > \frac{1}{|W|}] \quad (\text{в эксперименте } \sim 3.5\%)$$

Доля существенных тем в документах (document ratio):

$$DR = \frac{1}{|D|} \frac{1}{|T|} \sum_{d \in D} \sum_{t \in T} [\theta_{td} > \frac{1}{|T|}] \quad (\text{в эксперименте } \sim 11.5\%)$$

---

Koltcov S., Koltsova O., Nikolenko S. Latent Dirichlet Allocation: Stability and applications to studies of user-generated content // ACM WebSci, 2014.

## Методика эксперимента

Оставлены слова  $w$ , имеющие  $\phi_{wt} > \frac{1}{|W|}$  хотя бы в одной теме

Сокращение словаря (vocabulary reduction):  $154\text{ K} \rightarrow 8\text{ K}$ .

Дивергенция Кульбака–Лейблера между темами  $t$  и  $s$ :

$$\text{KL}(t, s) = \sum_{w \in W} p(w|t) \ln \frac{p(w|t)}{p(w|s)}$$

Нормированная KL-близость пар тем  $t$  и  $s$ :

$$\text{NKLS}(t, s) = \left( 1 - \frac{\text{KL}(t, s)}{\max_{t', s'} \text{KL}(t', s')} \right)$$


При  $\text{NKLS}(t, s) > 0.9$  в темах совпадают 30–50 топовых слов, и эксперты-социологи признают такие темы одинаковыми.

---

Koltcov S., Koltsova O., Nikolenko S. Latent Dirichlet Allocation: Stability and applications to studies of user-generated content // ACM WebSci, 2014.

## Неустойчивость LDA в разных запусках

Результат эксперимента: нормированная KL-близость NKLS между темой  $t$  и ближайшей к ней  $s$  в другом запуске.



1. Менее 50% тем воспроизводятся от запуска к запуску.
2. Плохо воспроизводятся как мусорные темы, так и хорошие.

---

Koltcov S., Koltsova O., Nikolenko S. Latent Dirichlet Allocation: Stability and applications to studies of user-generated content // ACM WebSci, 2014.

## Выводы из экспериментов

- ❶ Матрицы  $\Phi$ ,  $\Theta$  устойчиво восстанавливаются только при сильной разреженности  $\Phi_0$ ,  $\Theta_0$  (более 90% нулей)
- ❷ Произведение  $\Phi\Theta$  восстанавливается устойчиво, независимо от разреженности исходных  $\Phi_0$ ,  $\Theta_0$
- ❸ В разных запусках с использованием случайных начальных приближений или сэмплирования EM-алгоритм находит существенно отличающиеся наборы тем
- ❹ Распределение Дирихле — слишком слабый регуляризатор

---

Vorontsov K. V., Potapenko A. A. Additive Regularization of Topic Models // Machine Learning. Springer, 2015.


Koltcov S., Koltsova O., Nikolenko S. Latent Dirichlet Allocation: Stability and applications to studies of user-generated content // ACM WebSci, 2014.

## Напоминание. Дивергенция Кульбака–Лейблера


- $KL(P\|Q) \geq 0$ ;  $KL(P\|Q) = 0 \Leftrightarrow P = Q$ ;
- 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  $\ln x$  другой монотонной функцией  $\mu(x)$ ?

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

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  $\Phi$ :

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

---

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.

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:

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

**Эффект:** обнуляются строки матрицы  $\Theta$  с малыми  $n_t$ ,  
заодно получается удалить зависимые и расщеплённые темы.

---

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, Рр. 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:  $|D'| = 174$ .

---

Vorontsov K. V., Potapenko A. A. Tutorial on Probabilistic Topic Modeling:  
 Additive Regularization for Stochastic Matrix Factorization. AIST'2014.


## 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* 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 надёжноходим  $|T| = 50$ ,
- в широком интервале значений коэффициента  $\tau$ ;
- однако на реальных данных нет столь чёткого интервала.

## Сравнение с байесовской тематической моделью HDP


HDP, Hierarchical Dirichlet Process [Tech 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 флюкутирует 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.

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