

# Вероятностные тематические модели

## Лекция 4. Аддитивная регуляризация тематических моделей

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 Аддитивная регуляризация тематических моделей

- Максимизация регуляризованного правдоподобия
- Рациональный EM-алгоритм для ARTM
- Онлайновый EM-алгоритм для ARTM

## 2 Примеры полезных регуляризаторов

- 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

$D$  — коллекция текстовых документов  $d = \{w_1 \dots w_{n_d}\}$

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

$n_d$  — длина документа  $d$

Найти: модель  $p(w|d) = \sum_t \phi_{wt} \theta_{td}$  с параметрами  $\phi, \theta$ :

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

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

Критерий: максимум логарифма правдоподобия:

$$\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} \rightarrow \max_{\phi, \theta},$$

при ограничениях нормировки и неотрицательности

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

## Напоминание. Модель LDA (Latent Dirichlet Allocation)

Максимум апостериорной вероятности

$$\underbrace{\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td}}_{\text{ln правдоподобия } \mathcal{L}(\Phi, \Theta)} + \underbrace{\sum_{t,w} \beta_w \ln \phi_{wt} + \sum_{d,t} \alpha_t \ln \theta_{td}}_{\text{регуляризатор } R(\Phi, \Theta)} \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений

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

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

## ARTM – Аддитивная Регуляризация Тематических Моделей

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

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

EM-алгоритм: метод простой итерации для системы уравнений

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

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

Воронцов К. В. Аддитивная регуляризация тематических моделей коллекций текстовых документов. Доклады РАН, 2014. Т. 455., № 3. 268–271.

## Условия невырожденности решения

Решение может быть вырожденным для некоторых тем (столбцов матриц  $\Phi$ ) и документов (столбцов матрицы  $\Theta$ ).

*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  $\mu_i$ ,  $i = 1, \dots, m$ ,  $\lambda_j$ ,  $j = 1, \dots, k$ :

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

## Вывод системы уравнений из условий Каруша–Куна–Таккера

- Условия ККТ для  $\phi_{wt}$ ,  $w \in W$  (для  $\theta_{td}$  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  $\phi_{wt}$  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  $\lambda_t$  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  $\tau_i$  — коэффициенты регуляризации.

EM-алгоритм: метод простой итерации для системы уравнений

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

## Рациональный EM-алгоритм для ARTM

**Идея:** Е-шаг встраивается внутрь М-шага

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

**Выход:** матрицы терминов тем  $\Theta$  и тем документов  $\Phi$ ;

инициализация  $\phi_{wt}, \theta_{td}$  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 дисконтирования  $\rho \in (0, 1]$ ;

**Выход:** матрица  $\Phi$ :

инициализировать  $\phi_{wt}$  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  $D_b$ ,  $b = 1, \dots, B$

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

если пора выполнить синхронизацию, то

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

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

**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**  $\theta_d$  не сойдётся;


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

## Напоминание. Дивергенция Кульбака–Лейблера

1.  $KL(P\|Q) \geq 0$ ;  $KL(P\|Q) = 0 \Leftrightarrow P = Q$ ;
2. Минимизация  $KL$  эквивалентна максимизации правдоподобия:


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

3. 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  $\alpha_t$ .

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

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  $\alpha_t$ .

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

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  $t$ :

- $\beta_{wt} = [w \in W_t]$  — по словарю терминов  $W_t \subset W$
- $\alpha_{td} = [d \in D_t]$  — по списку документов  $D_t \subset D$

## 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



## 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

**Гипотеза:** если в теме слишком мало слов, то она не нужна.

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:

$$\theta_{td} = \operatorname{norm}_{t \in T} \left( n_{td} - \tau \frac{n_d}{n_t} \theta_{td} \right)_+$$

**Эффект:** строки матрицы  $\Theta$  могут целиком обнуляться для тем  $t$ , собравших мало слов по коллекции,  $n_t = \sum_d \sum_w n_{dwt}$ .

---

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 фоновых слов:  $\frac{1}{n} \sum_{d \in D} \sum_{w \in d} \sum_{t \in B} p(t|d, w)$

## 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  $\phi_{wt}$ .

$\text{PMI}(u, v) = \ln \frac{|D| N_{uv}}{N_u N_v}$  — поточечная взаимная информация (pointwise mutual information),

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

$N_u$  — число 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: 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 показателей:

- 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
- $|W| = 13\text{K}$  — 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.

- Задача тематического моделирования некорректно поставлена, её решение не единствено 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 сглаживающего регуляризатора.
- В реальных коллекциях «оптимального числа тем» нет.
- Регуляризатор отбора тем в ARTM проще, устойчивее и в 100 раз быстрее «штатного» байесовского метода HDP.