

# Вероятностные тематические модели

## Лекция 2. Аддитивная регуляризация тематических моделей (ARTM)

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 2017

## 1 Теория ARTM

- EM-алгоритм для ARTM
- Мультимодальные тематические модели
- Оффлайновый и онлайнный EM-алгоритм

## 2 Модель латентного размещения Дирихле LDA

- Распределение Дирихле
- Максимизация апостериорной вероятности
- Мифы про LDA

## 3 Эксперименты

- Неустойчивость на синтетических данных
- Неустойчивость на реальных данных
- Задания

## Напоминание. Задача тематического моделирования


**Дано:** коллекция текстовых документов,  $p(w|d) = \frac{n_{dw}}{n_d}$

Вероятностная тематическая модель:

$$p(w|d) = \sum_{t \in T} p(w|t)p(t|d) = \sum_{t \in T} \phi_{wt}\theta_{td}$$

**Найти:** параметры модели  $\phi_{wt} = p(w|t)$ ,  $\theta_{td} = p(t|d)$

Это задача стохастического матричного разложения:



## Напоминание. PLSA (Probabilistic Latent Semantic Analysis)

**Задача:** найти максимум правдоподобия

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

при ограничениях неотрицательности и нормировки

$$\phi_{wt} \geq 0; \quad \sum_{w \in W} \phi_{wt} = 1; \quad \theta_{td} \geq 0; \quad \sum_{t \in T} \theta_{td} = 1$$

$$\begin{array}{l} \text{E-шаг:} \\ \text{M-шаг:} \end{array} \left\{ \begin{array}{l} n_{dwt} = n_{dw} \frac{\phi_{wt} \theta_{td}}{\sum_s \phi_{ws} \theta_{sd}}; \\ \phi_{wt} = \frac{n_{wt}}{n_t}; \quad n_{wt} = \sum_{d \in D} n_{dwt}; \quad n_t = \sum_w n_{wt} \\ \theta_{td} = \frac{n_{td}}{n_d}; \quad n_{td} = \sum_{w \in d} n_{dwt}; \quad n_d = \sum_t n_{td} \end{array} \right.$$

## Задачи, некорректно поставленные по Адамару

Задача *корректно поставлена*,  
если её решение

- существует,
- единственно,
- устойчиво.



Жак Саломон Адамар  
(1865–1963)

Задача стохастического матричного разложения *некорректно поставлена*, так как имеется бесконечное множество решений:

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

для невырожденных  $S_{T \times T}$  таких, что  $\Phi', \Theta'$  — стохастические.

**Регуляризация** — стандартный приём, введение новых ограничений или критериев, доопределяющих решение.

# ARTM — Аддитивная Регуляризация Тематических Моделей

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

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

где  $\operatorname{norm}_{t \in T}(x_t) = \frac{\max\{x_t, 0\}}{\sum_{s \in T} \max\{x_s, 0\}}$  — операция нормирования вектора.

## 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:

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

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

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



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

1. Условия ККТ для  $\phi_{wt}$  (для  $\theta_{td}$  всё аналогично):

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

2. Умножим обе части равенства на  $\phi_{wt}$  и выделим  $p_{tdw}$ :

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

3. Если  $\lambda_t \leq 0$ , то тема  $t$  вырождена,  $\phi_{wt} \equiv 0$  для всех  $w$ .

4. Если  $\lambda_t > 0$ , то либо  $\phi_{wt} = 0$ , либо  $n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} > 0$ :

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

5. Суммируем обе части равенства по  $w \in W$ :

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

6. Подставим  $\lambda_t$  из (5) в (4), получим требуемое. ■

## Комбинирование регуляризаторов

Максимизация  $\log$  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.

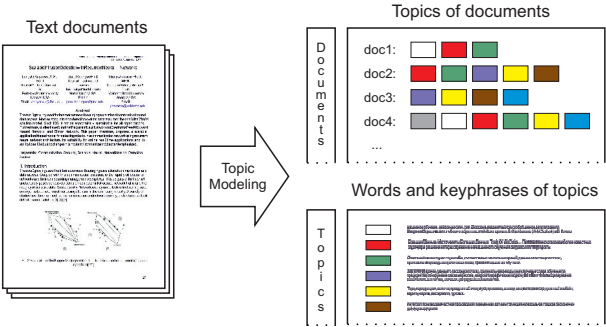
EM-алгоритм: метод простой итерации для системы уравнений

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

# Тематика (тематический вектор, тематический профиль)

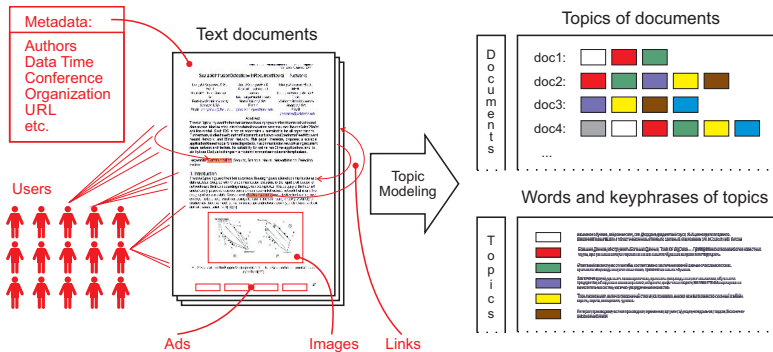
Тематика документа:  $p(t|d) = \theta_{td}$

Тематика термина:  $p(t|w) = p(w|t)p(t)/p(w) = \phi_{wt}n_t/n_w$



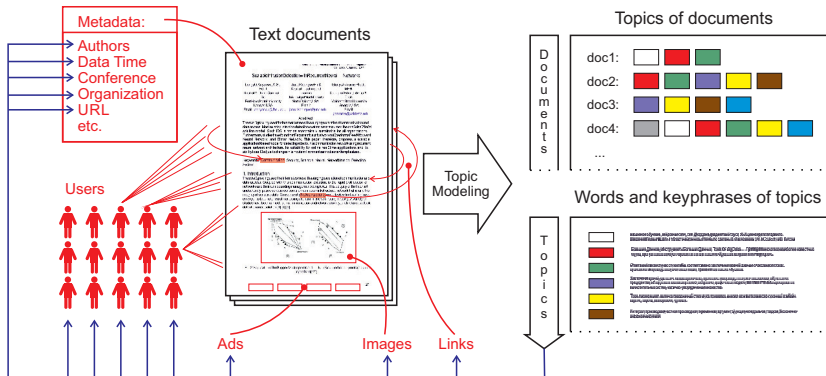
# Мультимодальная тематическая модель

Документ — универсальный контейнер не только терминов, но и токенов других модальностей:  $p(t|автор)$ ,  $p(t|время)$ ,  $p(t|ссылка)$ ,  $p(t|баннер)$ ,  $p(t|изображение)$ ,  $p(t|пользователь)$



## Мультимодальная тематическая модель

Документы могут содержать *токены* разных модальностей.  
 Каждая *модальность*  $t \in M$  описывается своим словарём  $W^m$ .  
 Каждая тема имеет своё распределение  $\phi_{wt} = p(w|t)$  на  $W^m$ .



# Мультимодальная ARTM

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

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

Максимизация суммы  $\log$  правдоподобий с регуляризацией:

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

EM-алгоритм: метод простой итерации для системы уравнений

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

## Оффлайновый EM-алгоритм для ARTM

Идея: E-шаг встраивается внутрь M-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**  $d \in D, m \in M, w \in d \cap W^m$

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

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

$\phi_{wt} := \text{norm}_{w \in W^m} (n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}})$  для всех  $m \in M, w \in W^m, t \in T$ ;

$\theta_{td} := \text{norm}_{t \in T} (n_{td} + \theta_{td} \frac{\partial R}{\partial \theta_{td}})$  для всех  $d \in D, t \in T$ ;

## Онлайнный EM-алгоритм для ARTM

Идея: коллекция  $D$  разбивается на пакеты  $D_b$ ,  $b = 1, \dots, B$

**Вход:** коллекция  $D$ ,  $\delta \equiv \text{decay\_weight}$ ,  $\alpha \equiv \text{apply\_weight}$ ;

**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 обновить матрицу  $\Phi$  **то**

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

$\phi_{wt} := \text{norm}_{w \in W^m} (n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}})$  для всех  $m \in M$ ,  $w \in W^m$ ,  $t \in T$ ;

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



## ProcessBatch: обработка пакета в онлайнном EM-алгоритме

**Идея:** обработать пакет, не меняя матрицу  $\Phi$

**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**

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

пост-обработка матрицы  $(p_{tdw})_{T \times n_d}$  при необходимости;

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

**пока**  $\theta_d$  не сойдётся;

$\tilde{n}_{wt} := \tilde{n}_{wt} + \tau_m n_{dw} p_{tdw}$  для всех  $m \in M$ ,  $w \in W^m$ ,  $t \in T$ ;

## Сравнение оффлайнового и онлайнного алгоритмов

### Оффлайн EM-алгоритм:

- 1 многократное итерирование по коллекции
- 2 однократный проход по документу
- 3 хранение матрицы  $\Theta$
- 4 обновление  $\Phi$  в конце каждого прохода по коллекции
- 5 применяется при обработке небольших коллекций

### Онлайн EM-алгоритм:

- 1 однократный проход по коллекции
- 2 многократное итерирование по каждому документу
- 3 нет необходимости хранить матрицу  $\Theta$
- 4 обновление  $\Phi$  через заданное число пакетов
- 5 применяется при потоковой обработке больших коллекций

## Гипотеза об априорных распределениях Дирихле

Вероятностная тематическая модель:  $p(w|d) = \sum_{t \in T} \underbrace{p(w|t)}_{\phi_{wt}} \underbrace{p(t|d)}_{\theta_{td}}$

1. Пусть  $\theta_d = (\theta_{td})_{t \in T} \in \mathbb{R}^{|T|}$  — случайные векторы из распределения Дирихле с параметром  $\alpha \in \mathbb{R}^{|T|}$ :

$$\text{Dir}(\theta_d | \alpha) = \frac{\Gamma(\alpha_0)}{\prod_t \Gamma(\alpha_t)} \prod_t \theta_{td}^{\alpha_t - 1}, \quad \theta_{td} > 0; \quad \alpha_0 = \sum_t \alpha_t, \quad \alpha_t > 0;$$

2. Пусть  $\phi_t = (\phi_{wt})_{w \in W} \in \mathbb{R}^{|W|}$  — случайные векторы из распределения Дирихле с параметром  $\beta \in \mathbb{R}^{|W|}$ :

$$\text{Dir}(\phi_t | \beta) = \frac{\Gamma(\beta_0)}{\prod_w \Gamma(\beta_w)} \prod_w \phi_{wt}^{\beta_w - 1}, \quad \phi_{wt} > 0; \quad \beta_0 = \sum_w \beta_w, \quad \beta_w > 0;$$

---

Blei D., Ng A., Jordan M. Latent Dirichlet Allocation // JMLR, 2003.

## Вероятностная модель порождения текста

Тематическая модель LDA (Latent Dirichlet Allocation):

$$p(w|d) = \sum_{t \in T} \phi_{wt} \theta_{td}, \quad \phi_t \sim \text{Dir}(\phi|\beta), \quad \theta_d \sim \text{Dir}(\theta|\alpha).$$

Процесс порождения документов  $d = \{w_1 \dots w_{n_d}\}$  коллекции  $D$ :

**Вход:** векторы гиперпараметров  $\beta, \alpha$ ;

**Выход:** коллекция документов;

выбрать вектор  $\phi_t$  из  $\text{Dir}(\phi|\beta)$  для каждой темы  $t \in T$ ;

выбрать вектор  $\theta_d$  из  $\text{Dir}(\theta|\alpha)$  для каждого документа  $d \in D$ ;

**для всех** документов  $d \in D$

**для всех** позиций слов  $i = 1, \dots, n_d$  в документе  $d$


выбрать тему  $t_i$  из  $p(t|d) \equiv \theta_{td}$ ;

выбрать слово  $w_i$  из  $p(w|t_i) \equiv \phi_{wt_i}$ ;


## Почему именно распределение Дирихле?

- Может порождать сглаженные или разреженные векторы
- Имеет параметры, управляющие степенью разреженности
- Неплохо описывает кластерные структуры на симплексе
- Является сопряжённым к мультиномиальному распределению


**Пример.**  $\text{Dir}(\theta|\alpha)$  при  $|T| = 3$ ,  $\theta, \alpha \in \mathbb{R}^3$ :



$$\alpha_1 = \alpha_2 = \alpha_3 = 0.1$$




$$\alpha_1 = \alpha_2 = \alpha_3 = 1$$




$$\alpha_1 = \alpha_2 = \alpha_3 = 10$$


## Распределение $\text{Dir}(\theta_d|\alpha)$ при $\alpha_t \equiv 100$ , 10 тем, 15 документов



## Распределение $\text{Dir}(\theta_d|\alpha)$ при $\alpha_t \equiv 10$ , 10 тем, 15 документов




## Распределение $\text{Dir}(\theta_d|\alpha)$ при $\alpha_t \equiv 1$ , 10 тем, 15 документов






## Распределение $\text{Dir}(\theta_d|\alpha)$ при $\alpha_t \equiv 0.1$ , 10 тем, 15 документов



## Распределение $\text{Dir}(\theta_d|\alpha)$ при $\alpha_t \equiv 0.01$ , 10 тем, 15 документов



## Максимизация апостериорной вероятности для модели LDA

Совместное правдоподобие данных и модели:

$$\ln \prod_{d \in D} \prod_{w \in d} p(d, w | \Phi, \Theta)^{n_{dw}} \prod_{t \in T} \text{Dir}(\phi_t | \beta) \prod_{d \in D} \text{Dir}(\theta_d | \alpha) \rightarrow \max_{\Phi, \Theta}$$

Принцип MAP (maximum a posteriori probability)

$$\begin{aligned} \sum_{d \in D} \sum_{w \in d} n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} + \\ + \sum_{t \in T} \sum_{w \in W} \ln \phi_{wt}^{\beta_w - 1} + \sum_{d \in D} \sum_{t \in T} \ln \theta_{td}^{\alpha_t - 1} \rightarrow \max_{\Phi, \Theta} \end{aligned}$$

при ограничениях неотрицательности и нормировки

$$\phi_{wt} \geq 0; \quad \sum_{w \in W} \phi_{wt} = 1; \quad \theta_{td} \geq 0; \quad \sum_{t \in T} \theta_{td} = 1.$$

## Регуляризованный EM-алгоритм для модели LDA

Максимум апостериорной вероятности:

$$\underbrace{\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td}}_{\text{ln правдоподобия } \mathcal{L}(\Phi, \Theta)} + \underbrace{\sum_{t,w} (\beta_w - 1) \ln \phi_{wt} + \sum_{d,t} (\alpha_t - 1) \ln \theta_{td}}_{\text{критерий регуляризации } R(\Phi, \Theta)} \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{cases} \text{E-шаг:} & p_{tdw} = \mathop{\text{norm}}_{t \in T}(\phi_{wt} \theta_{td}) \\ \text{M-шаг:} & \begin{cases} \phi_{wt} = \mathop{\text{norm}}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} + \beta_w - 1 \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in D} n_{dw} p_{tdw} + \alpha_t - 1 \right) \end{cases} \end{cases}$$

## Мифы про LDA

- LDA существенно меньше переобучается, чем PLSA
- LDA строит более разреженную тематическую модель
- LDA имеет меньше параметров по сравнению с PLSA
- LDA == тематическое моделирование

На самом деле,

- LDA отличается от PLSA только на малых  $n_{wt}$ ,  $n_{td}$
- LDA имеет больше параметров по сравнению с PLSA
- LDA не имеет убедительных лингвистических обоснований
- LDA не решает проблему неединственности разложения
- LDA — слабый и неинтересный регуляризатор

---

*Asuncion A., Welling M., Smyth P., Teh Y. W. On smoothing and inference for topic models. Int'l Conf. on Uncertainty in Artificial Intelligence, 2009.*

## 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 К  $\rightarrow$  8 К.

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

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

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

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


При  $NKLS(t, s) > 0.9$  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-GS 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

- 1 Матрицы  $\Phi$ ,  $\Theta$  устойчиво восстанавливаются только при сильной разреженности  $\Phi_0$ ,  $\Theta_0$  (более 90% нулей)
- 2 Произведение  $\Phi\Theta$  восстанавливается устойчиво, независимо от разреженности исходных  $\Phi_0$ ,  $\Theta_0$
- 3 В разных запусках с использованием случайных начальных приближений или сэмплирования EM-алгоритм находит существенно различающиеся наборы тем

---

*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.*

- Задача тематического моделирования некорректно поставлена, её решение не единственно и не устойчиво.
- Регуляризация — стандартный приём решения таких задач.
- Подход ARTM позволяет комбинировать регуляризаторы и строить тематические модели с требуемыми свойствами.
- Реализация — в проекте с открытым кодом BigARTM.
- Модель LDA — слишком слабый регуляризатор, не решает проблему неединственности и неустойчивости.
- Модель LDA лучше описывает вероятности редких слов, но для выявления тематики они как раз и не важны.
- Регуляризаторы и модальности — в следующих лекциях.

## Прикладные проекты и исследовательские задачи

- Медиапланирование. Поток новостей. Иерархия тем.
- Контакт-центр. Обучение тем. Сегментация. Сценарии.
- Новостной мониторинг. Обучение тем. Поиск проблем.
- Финансовые транзакции. Трёхматричная модель.
- Агрегатор научно-популярного контента в Рунете.
- Разведочный поиск по Хабру. Улучшение модели.
- Исследование устойчивости.
- Исследование онлайн-алгоритма.
- Исследование инициализаций матрицы  $\Phi$ .
- Адаптивная оптимизация коэффициентов регуляризации.
- Распознавание новых тем в потоке новостей.
- Тематическая сегментация.
- Суммаризация тем.
- Автоматическое именование тем.
- SyntaxNet. Автоматическое выделение терминов.