

# Вероятностные тематические модели

## Лекция 3. Аддитивная регуляризация тематических моделей (ARTM)

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 Теория ARTM

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

## 2 Модель латентного размещения Дирихле LDA

- Распределение Дирихле
- Максимизация апостериорной вероятности
- Миры про LDA

## 3 Проекты. Задания. Открытые проблемы

- Прикладные проекты
- Примеры заданий по спецкурсу
- Открытые проблемы

## 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

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

E-шаг:  $n_{dwt} = n_{dw} \frac{\phi_{wt} \theta_{td}}{\sum_s \phi_{ws} \theta_{sd}}$

M-шаг:  $\begin{cases} \phi_{wt} = \frac{n_{wt}}{n_t}; & n_{wt} = \sum_{d \in D} n_{dwt}; & n_t = \sum_w n_{wt} \\ \theta_{td} = \frac{n_{td}}{n_d}; & n_{td} = \sum_{w \in d} n_{dwt}; & n_d = \sum_t n_{td} \end{cases}$

## 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  $R$ :

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

ЕМ-алгоритм: метод простой итерации для системы уравнений

Е-шаг:  $p_{tdw} \equiv p(t|d, w) = \text{norm}_{t \in T}(\phi_{wt} \theta_{td})$

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

где  $\text{norm}_{t \in T}(x_t) = \frac{\max\{x_t, 0\}}{\sum\limits_{s \in T} \max\{x_s, 0\}}$  — 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:

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

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  $\phi_{wt}$  (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  $\log$  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.


ЕМ-алгоритм: метод простой итерации для системы уравнений

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

# 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*:  $p(t|\text{автор})$ ,  $p(t|\text{время})$ ,  $p(t|\text{ссылка})$ ,  $p(t|\text{баннер})$ ,  $p(t|\text{изображение})$ ,  $p(t|\text{пользователь})$




# Мультимодальная тематическая модель

Документы могут содержать токены разных модальностей.

Каждая модальность  $m \in M$  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,  $m \in M$

$W = W^1 \sqcup \cdots \sqcup W^M$  — 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

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

# 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  $\Theta$  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  $d \in D, t \in T$ ;

# Онлайновый 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  $w \in W$ ,  $t \in T$ ;

$\phi_{wt} := \underset{w \in W^m}{\text{norm}} \left( n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)$  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 онлайновом 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**

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

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

$\theta_{td} := \text{norm} \left( \sum_{t \in T} \tau_m \sum_{w \in W^m} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right)$  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 онлайнового алгоритмов

## Оффлайн EM-алгоритм:

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

## Онлайн EM-алгоритм:

- ❶ однократный проход по коллекции
- ❷ многократное итерирование по каждому документу
- ❸ нет необходимости хранить матрицу  $\Theta$
- ❹ обновление  $\Phi$  через заданное число пакетов
- ❺ 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  $p(w|t_i) \equiv \phi_{wt}$ ;


## 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

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

## 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.

## Далее в этом разделе

- Прикладные проекты
  - текущие проекты, в которых есть данные, команда и примерное понимание путей решения
  - каждый проект слишком большой, чтобы делать его в одиночку, но разбивается на более простые подзадачи
- Задания по спецкурсу
  - практические задачи из проектов
  - синтетические задачи на исследование алгоритмов
  - задания по подготовке обзоров с докладом на семинаре
- Открытые проблемы
  - наука здесь!
  - перспективные направления исследований для дальнейшей работы в научной группе
  - творческие исследовательские задачи без чётких постановок и заранее известных правильных ответов

# 1. Новостной мониторинг для медиапланирования

- **Дано:**

поток новостей СМИ ( $\sim 100\text{ K}/\text{день}$ ) и социальных медиа.

- **Найти:**

- 1) иерархическая тематическая модель,
- 2) спектр тем и спектр мнений по заданному тексту,
- 3) фильтр потока по заданным спектрам тем и мнений,
- 4) оценки разнообразия тем и мнений в потоке.

- **Критерий:**

- 1) интерпретируемость и различность тем,
- 2) интерпретируемость разделения тем на подтемы,
- 3) ассессорские оценки качества (около 10 критериев):
  - точность распознавания новых тем,
  - точность распознавания слов общей лексики и др.

## 2. Новостной мониторинг для поиска проблемных компаний

- **Дано:**

- 1) поток новостных сообщений СМИ,
- 2) семантические ядра тем по компаниям,
- 3) семантические ядра тем по проблемным ситуациям,
- 4) подвыборка известных случаев проблемных ситуаций.

- **Найти:**

- 1) сообщения о проблемных ситуациях по компаниям,
- 2) все темы по каждой компании,
- 3) новые типы проблемных ситуаций.

- **Критерий:**

- 1) интерпретируемость всех тем,
- 2) точность и полнота поиска по известным случаям.

### 3. Сценарный анализ записей разговоров контакт-центра

- **Дано:**

- 1) коллекция текстов разговоров,
- 2) семантические ядра (обучающие тексты) тем,
- 3) сегментная разметка подвыборки разговоров.

- **Найти:**

- 1) граф сценариев разговоров,
- 2) вероятность успешного исхода в любой точке разговора,
- 3) онлайновые подсказки оператору,
- 4) автоматические оценки качества работы операторов,
- 5) рекомендации операторам.

- **Критерий:**

- 1) точность выделения тем в разговорах,
- 2) точность сегментации на размеченной подвыборке.

## 4. Агрегатор русскоязычного научно-популярного контента

- **Дано:**

- 1) коллекции статей научно-популярных порталов,
- 2) коллекция Википедии на русском языке.

- **Найти:**

- 1) общая тематическая иерархия,
- 2) контекстные рекомендации по заданному тексту,
- 3) тематический разведочный поиск по заданному тексту,
- 4) интерактивная графическая «карта знаний».

- **Критерий:**

- 1) полнота и точность поиска,
- 2) интерпретируемость и различность тем,
- 3) интерпретируемость разделения тем на подтемы,
- 4) точность асессорского поиска документа по иерархии,
- 5) экспертные оценки «интересности» рекомендаций.

## 5. Тематический разведочный поиск по коллективному блогу

- **Дано:**

- 1) коллекция Habrahabr.ru или TechCrunch.com,
- 2) выборка тематических запросов (длинные тексты),
- 3) асессорские оценки релевантности документов запросам.

- **Найти:**

- 1) тематическая модель для разведочного поиска,
- 2) признаки сходства тематических векторов,
- 3) функции ранжирования документов по запросу.

- **Критерий:**

- 1) точность и полнота поиска,
- 2) качество ранжирования (MAP или NDCG).

---

Янина А.О., Воронцов К.В. Мультимодальные тематические модели для разведочного поиска в коллективном блоге. JMLDA. 2016.

## 6. Кросс-язычный разведочный поиск по патентной базе

- **Дано:**

- 1) коллекция патентов США на английском языке,
- 2) коллекция их машинных переводов на русский язык,
- 3) коллекция двуязычных статей Википедии,
- 4) выборка русскоязычных запросов (длинные тексты),
- 5) асессорские оценки релевантности документов запросам.

- **Найти:**

- 1) тематическая иерархия научно-технической информации,
- 2) признаки сходства тематических векторов,
- 3) функции ранжирования документов по запросу.

- **Критерий:**

- 1) точность и полнота кросс-язычного поиска,
- 2) качество ранжирования (MAP или NDCG).

## 7. Построение продуктовой иерархии по текстам госзакупок

- **Дано:**

- 1) описания объектов закупок ( $\sim 200$  млн.),
- 2) общероссийский классификатор продукции ОКПД.

- **Найти:**

иерархический тематический классификатор продуктов.

- **Критерий:**

- 1) интерпретируемость и различность тем,
- 2) интерпретируемость разделения тем на подтемы,
- 3) согласованность верхних уровней с ОКПД,
- 4) точность ассессорского поиска товара по иерархии.

## 8. Выявление структуры отрасли по транзакционным данным

- **Дано:**

- 1) база банковских транзакций между компаниями,
- 2) коды ОКВЭД для компаний.

- **Найти:**

- 1) латентные темы — виды экономической деятельности,
- 2) их соответствие ОКВЭДам,
- 3) граф товарно-денежных потоков отрасли,
- 4) типовые бизнес-схемы компаний — лидеров отрасли.

- **Критерий:**

- 1) точность описания транзакционных данных,
- 2) интерпретируемость графа отрасли.

## 9. Диагностика заболеваний по электрокардиограмме

- **Дано:**

- 1) электрокардиограммы, закодированные в символьные последовательности методом В.М.Успенского,
- 2) диагнозы по 32 заболеваниям для каждой ЭКГ.

- **Найти:**

- 1) диагностические эталоны каждого заболевания,
- 2) решающее правило по каждому заболеванию.

- **Критерий:**

- 1) чувствительность и специфичность диагностики,
- 2) качество ранжирования диагнозов.

## Тематическая модель классификации с частичным обучением

- **Дано:**  
коллекция текстов, частично классифицированных
- **Цель:**  
исследовать зависимость качества тематической классификации от числа классифицированных документов
- **Этапы решения:**
  - 1) разделить коллекцию на обучение и тест,
  - 2) построить классификатор, используя только классифицированные документы,
  - 3) улучшить качество классификации путём использования неразмеченных данных.

## Переобучение тематической модели классификации

- **Дано:**

коллекция текстов, классифицированных по темам

- **Цель:**

исследовать зависимость переобучения от стратегии  
разреживания матрицы  $\Theta$

- **Этапы решения:**

- 1) разделить коллекцию на обучение и тест
- 2) построить тематические модели классификации при различных стратегиях разреживания
- 3) подобрать оптимальный режим регуляризации

## Фоновые темы в двухуровневой иерархии

- **Дано:**

коллекция новостей, двухуровневая тематическая иерархия

- **Цель:**

сравнить несколько стратегий регуляризации фоновых тем

- **Этапы решения:**

- 1) фоновые темы переходят с родительского уровня на дочерний
- 2) фоновые темы дочернего уровня не зависят от родительского
- 3) для каждой родительской темы выделяется своя фоновая тема

## Динамическая тематическая модель новостного потока

- **Дано:**

коллекция новостей

- **Цель:**

построить критерий, решающий, создавать ли новую тему или продолжать существующую

- **Этапы решения:**

- 1) построить тематическую модель коллекции новостей
- 2) построить алгоритм добавления блока новостей
- 3) составить и разметить выборку пар «новость–продолжение»
- 4) оптимизировать пороговое правило в критерии

## Сравнение триплетов статей arXiv

- **Дано:**
  - 1) коллекция статей arXiv,
  - 2) набор триплетов статей
- **Цель:**

показать, что тематические модели решают задачу семантической близости документов
- **Этапы решения:**
  - 1) восстановить соответствие документов коллекции статей arXiv и url статей,
  - 2) Обучить нейронную сеть Paragraph2vec и тематическую модель ARTM на коллекции статей arXiv,
  - 3) добиться для обеих моделей результатов, сопоставимых с результатами статьи

## Конкурс Fakenews Challenge

- **Дано:**

Коллекция англоязычных новостей и их заголовков, поделённая на 2 широких класса (*relevant, not relevant*) и 4 узких (*discuss, agree, disagree, not relevant*)

- **Цель:**

- 1) определение релевантности заголовка статьи,
- 2) проверка адекватности тематического моделирования.

- **Этапы решения:**

- 1) предобработка, разбиение коллекции для кросс-валидации,
- 2) тематическое моделирование, кросс-валидация,
- 3) сравнение с другими моделями (LR, SVM),
- 4) добиться улучшения качества модели путём регуляризации.

## Темы исследований, где есть открытые проблемы

- Устойчивость и полнота набора тем.
- Оптимизация параметров онлайнового алгоритма.
- Адаптивная оптимизация коэффициентов регуляризации.
- Эффективная инициализация матрицы  $\Phi$ .
- Создание новых тем в потоке новостей.
- Автоматическое выделение терминов-словосочетаний.
- Тематическая сегментация.
- Тематические модели дистрибутивной семантики.
- Суммаризация тем.
- Автоматическое именование тем.
- Интеграция с анализом тональности и выявлением мнений.
- Интеграция с синтаксическими анализаторами.

- Задача тематического моделирования некорректно поставлена, её решение не единствено 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.