

# Вероятностные тематические модели

## Лекция 9.

### Модели локальных контекстов

К. В. Воронцов

k.v.vorontsov@phystech.edu

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Вероятностные тематические модели (курс лекций, К.В.Воронцов)»

## 1 Линейная тематизация текста

- Однопроходный Е-шаг
- Локализованный Е-шаг
- Двунаправленные векторы контекста

## 2 Модели внимания и трансформеры

- Модели внимания
- Трансформер кодировщик
- Трансформер декодировщик

## 3 На пути к тематическим моделям внимания

- Локализованный Е-шаг и модель внимания
- Локализованный Е-шаг и трансформер
- Онлайновый EM-алгоритм с локализованным Е-шагом

## Напоминание. Задача тематического моделирования

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

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

**Критерий:** максимум **регуляризованного** log-правдоподобия:

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

EM-алгоритм: метод простой итерации для системы уравнений

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

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

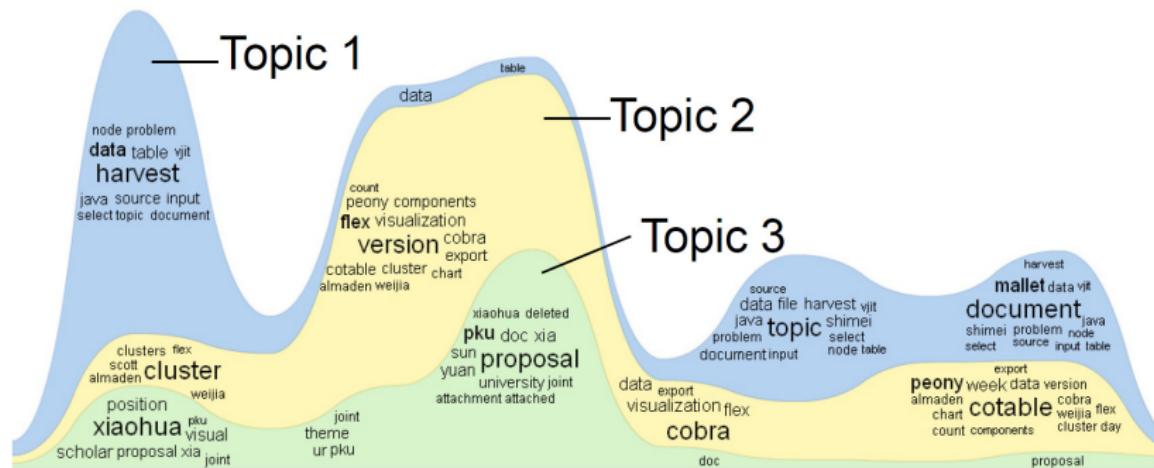
## Задача тематизации фрагмента текста

Ситуации, в которых необходим тематический вектор  $p(t|s)$  текстового фрагмента  $s$ , возможно, короткого:

- поиск в тексте фрагментов, наиболее релевантных запросу
- поиск наиболее тематичных предложений или фраз для
  - суммаризации документа (document summarization)
  - суммаризации темы (topic summarization)
  - автоматического именования темы (topic labeling)
- определение тематики нового слова/словосочетания по окружающему его локальному контексту  $s$
- тематические модели предложений
  - когда разбиение текста на предложения/секции задано
- тематические модели сегментации текста
  - когда границы сегментов требуется найти
- отображение карты распределения тем внутри документа

## Пример 1. Отображение распределения тем внутри документа

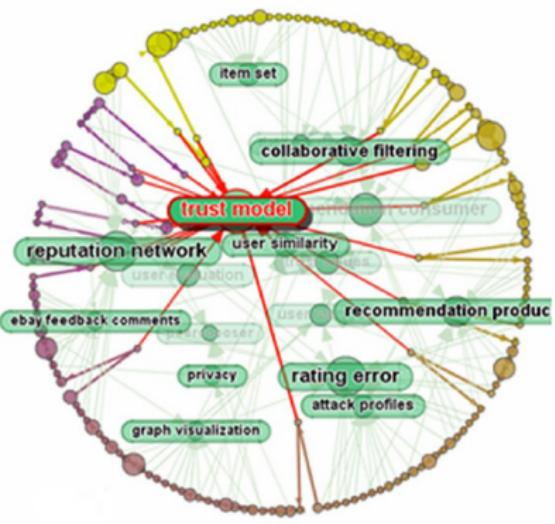
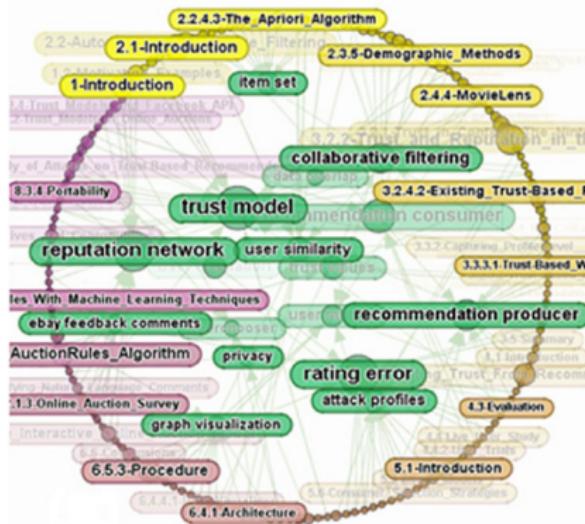
Визуализация динамики тем применяется к новостным потокам или к длинным документам, разбитым на сегменты.



Shixia Liu, Michelle X. Zhou, Shimei Pan, Yangqiu Song, Weihong Qian, Weijia Cai, Xiaoxiao Lian. TIARA: interactive, topic-based visual text summarization and analysis. 2012.

## Пример 2. Отображение распределения тем внутри документа

Динамика всех тем и одной выделенной темы в документе



Gretarsson B., O'Donovan J., Bostandjiev S., Hollerer T., Asuncion A., Newman D., Smyth P. TopicNets: visual analysis of large text corpora with topic modeling. 2012.

## Пример 3. Выделение сюжетных линий в длинных текстах

Иерархическая модель выделяет сюжетные линии (topics) и их сочетания (themes) в тексте художественного произведения



(a) Document

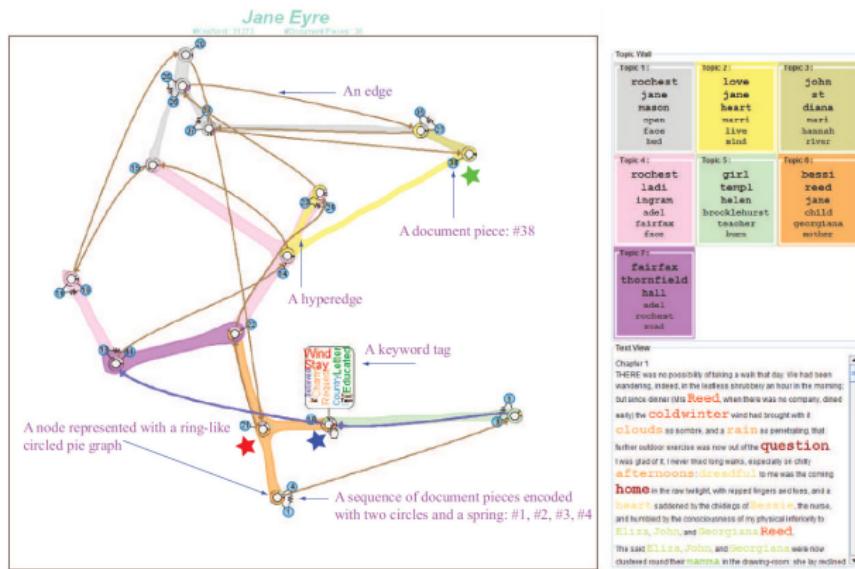
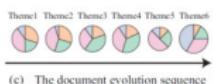
Topic 1  
Family, Father, Mother, Toy, Cry...

Topic 2  
School, Teacher, Book, Game...

Topic 3  
University, Enroll, Campus, Bus...

Topic 4  
Company, Career, Salary, Drive...

(b) Topics



Guizhen Wang, Chaokai Wen, Binghui Yan, Jing Xia, Zhen Liu, Wei Chen. Topic hypergraph: hierarchical visualization of thematic structures in long documents. 2012.

## Идея тематизации текста за один проход

**Дано:**  $s$  — фрагмент текста  $d$ ,  $\Phi$  — тематическая модель

**Найти:**  $p(t|s)$  — тематический вектор фрагмента текста

### Проблемы:

- как не переобучить вектор  $p(t|s)$ , если текст короткий?
- как согласовать  $p(t|s)$  с объемлющим контекстом  $p(t|d)$ ?
- как согласовать  $p(t|s)$  с  $p(t|w) = \phi_{wt} \frac{p(t)}{p(w)}$  термов  $w \in s$ ?

### Наводящие соображения:

- первая итерация ЕМ-алгоритма с инициализацией  $\theta_{td}^0 = \frac{1}{|T|}$ :

$$\theta_{td}(\Phi) = \text{norm} \left( \sum_{w \in W} n_{dw} p_{tdw} \right) = \sum_{w \in d} \frac{n_{dw}}{n_d} \text{norm} \left( \phi_{wt} \theta_{td}^0 \right)$$

- формула полной вероятности:

$$\theta_{td}(\Phi) = \sum_{w \in d} p(w|d) p(t|w) = \sum_{w \in d} \frac{n_{dw}}{n_d} \text{norm} \left( \phi_{wt} p_t \right)$$

## ЕМ-алгоритм для ARTM с явным выражением $\Theta$ через $\Phi$

Максимизация логарифма правдоподобия:

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

ЕМ-алгоритм: метод простой итерации для системы уравнений

$$p_{tdw} = \text{norm}_{t \in T}(\phi_{wt} \theta_{td}); \quad n_{td} = \sum_{w \in d} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}};$$

$$p'_{tdw} = p_{tdw} + \frac{1}{n_{dw}} \sum_{s \in T} \frac{n_{sd}}{\theta_{sd}} \phi_{wt} \frac{\partial \theta_{sd}}{\partial \phi_{wt}};$$

$$\phi_{wt} = \text{norm}_{w \in W} \left( \sum_{d \in D} n_{dw} p'_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right).$$

И.А.Ирхин, В.Г.Булатов, К.В.Воронцов. Аддитивная регуляризация тематических моделей с быстрой векторизацией текста. КиМ, 2020.

## Доказательство (по Лемме о максимизации на симплексах)

Оптимизационная задача М-шага относительно  $\Phi$  и  $\Theta(\Phi)$ :

$$Q(\Phi) = \sum_{d \in D} \sum_{u \in W} \sum_{s \in T} n_{du} p_{sdu} \ln(\phi_{us} \theta_{sd}(\Phi)) + R(\Phi, \Theta(\Phi)) \rightarrow \max_{\Phi}$$

Применим Лемму к регуляризованному log-правдоподобию  $Q$ :

$$\begin{aligned} \phi_{wt} \frac{\partial Q}{\partial \phi_{wt}} &= \sum_{d \in D} n_{dw} p_{tdw} + \sum_{d, s, u} n_{du} p_{sdu} \frac{\phi_{wt}}{\theta_{sd}} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} + \phi_{wt} \sum_{d, s} \frac{\partial R}{\partial \theta_{sd}} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} = \\ &= \sum_{d \in D} n_{dw} \left( p_{tdw} + \frac{1}{n_{dw}} \sum_{s \in T} \frac{\phi_{wt}}{\theta_{sd}} \underbrace{\left( \sum_{u \in d} n_{du} p_{sdu} + \theta_{sd} \frac{\partial R}{\partial \theta_{sd}} \right)}_{n_{sd}} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} \right) + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} = \\ &= \sum_{d \in D} n_{dw} \underbrace{\left( p_{tdw} + \frac{1}{n_{dw}} \sum_{s \in T} \frac{n_{sd}}{\theta_{sd}} \phi_{wt} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} \right)}_{p'_{tdw}} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}}. \end{aligned}$$

■

## EM-алгоритм для ARTM с линейной тематизацией документов

$$\theta_{td}(\Phi) = \sum_{w \in d} p_{wd} \underset{t \in T}{\text{norm}}(\phi_{wt} p_t) \Rightarrow \phi_{wt} \frac{\partial \theta_{sd}}{\partial \phi_{wt}} = p_{wd} \phi'_{tw} (\delta_{st} - \phi'_{sw})$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\phi'_{tw} = \underset{t \in T}{\text{norm}}(\phi_{wt} n_t); \quad \theta_{td} = \sum_{w \in d} p_{wd} \phi'_{tw};$$

$$p_{tdw} = \underset{t \in T}{\text{norm}}(\phi_{wt} \theta_{td}); \quad n_t = \sum_{d \in D} \sum_{w \in d} n_{dw} p_{tdw};$$

$$n_{td} = \sum_{w \in d} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}};$$

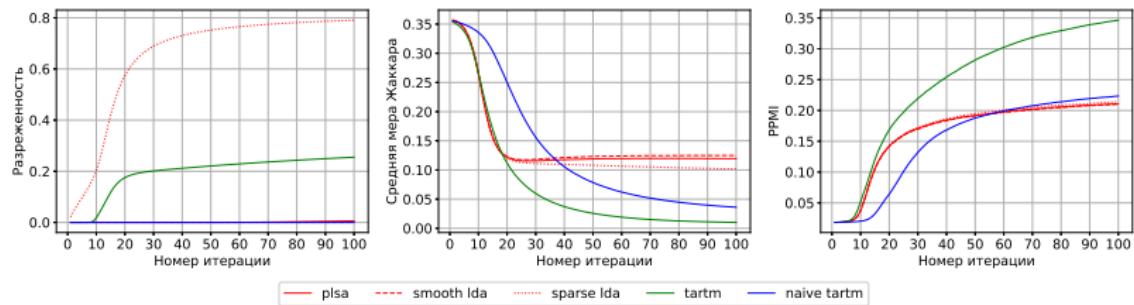
$$p'_{tdw} = p_{tdw} + \frac{\phi'_{tw}}{n_d} \left( \frac{n_{td}}{\theta_{td}} - \sum_{s \in T} \phi'_{sw} \frac{n_{sd}}{\theta_{sd}} \right);$$

$$\phi_{wt} = \underset{w \in W}{\text{norm}} \left( \sum_{d \in D} n_{dw} p'_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right).$$

## Эксперимент. Проверка модифицированного EM-алгоритма

Коллекция NIPS,  $|T| = 50$ , модели:

- TARTM ( $\Theta$ less ARTM) — модифицированный EM-алгоритм
- naive TARTM — одна итерация обычного EM-алгоритма



- TARTM очищает темы от общеупотребительных слов,
- улучшает разреженность, различность и когерентность тем

И.А.Ирхин, В.Г.Булатов, К.В.Воронцов. Аддитивная регуляризация тематических моделей с быстрой векторизацией текста, 2020.

## Упрощение EM-алгоритма для линейной тематизации

- Нет регуляризации по  $\Theta$ , следовательно,  $\frac{\partial R}{\partial \theta_{td}} = 0$
- Подстановка несмешённых оценок  $\theta_{td} = \frac{n_{td}}{n_d}$ ,  $\theta_{sd} = \frac{n_{sd}}{n_d}$  в формулу М-шага приводит к упрощению:  $p'_{tdw} = p_{tdw}$

EM-алгоритм: метод простой итерации для системы уравнений

$$\phi'_{tw} \equiv p(t|w) = \underset{t \in T}{\text{norm}}(\phi_{wt} n_t); \quad \theta_{td} = \sum_{w \in d} p_{wd} \phi'_{tw};$$

$$p_{tdw} \equiv p(t|d, w) = \underset{t \in T}{\text{norm}}(\phi_{wt} \theta_{td}); \quad n_t = \sum_{d \in D} \sum_{w \in d} n_{dw} p_{tdw};$$

$$\phi_{wt} = \underset{w \in W}{\text{norm}} \left( \sum_{d \in D} n_{dw} p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right).$$

Это обычный EM-алгоритм, только с однопроходным Е-шагом!  
ОГО! И ТАК МОЖНО БЫЛО?!

## Линейная тематизация: от документа к локальным контекстам

Тематизация документа  $d = (w_1, \dots, w_{n_d})$  за один проход:

$$\theta_{td}(\Phi) \equiv p(t|d) = \frac{1}{n_d} \sum_{i=1}^{n_d} p(t|w_i) = \frac{1}{n_d} \sum_{i=1}^{n_d} \phi'_{tw_i}$$

Тематизация локального контекста  $C_i = (\dots, w_i, \dots)$  терма  $w_i$ :

$$\theta_{ti}(\Phi) \equiv p(t|i) = \frac{1}{|C_i|} \sum_{u \in C_i} p(t|u) = \frac{1}{|C_i|} \sum_{u \in C_i} \phi'_{tu}$$

Тематизация локального контекста с распределением весов:

$$\theta_{ti}(\Phi) \equiv p(t|i) = \sum_{u \in C_i} \phi'_{tu} \alpha(u|i), \quad \sum_{u \in C_i} \alpha(u|i) = 1, \quad \alpha(u|i) \geq 0$$

Локализованная тематическая модель (похожа на BitermTM):

$$p(w|d, i) = \sum_{t \in T} p(w|t) p(t|i) = \sum_{t \in T} \phi_{wt} \sum_{u \in C_i} \phi'_{tu} \alpha(u|i)$$

## ЕМ-алгоритм с локализованным Е-шагом

$w_1, \dots, w_n$  — сквозная нумерация термов во всей коллекции

$C_i$  — локальный контекст (окружение) терма  $w_i$

$\alpha(u|i)$  — распределение важности термов  $u \in C_i$  для терма  $w_i$

- не нужна гипотеза «мешка слов»
- не нужно разбиение на документы

ЕМ-алгоритм: метод простой итерации для системы уравнений

$$\phi'_{tw} \equiv p(t|w) = \operatorname{norm}_{t \in T}(\phi_{wt} n_t); \quad \theta_{ti} = \sum_{u \in C_i} \phi'_{tu} \alpha(u|i);$$

$$p_{ti} \equiv p(t|d, w_i) = \operatorname{norm}_{t \in T}(\phi_{w_i t} \theta_{ti}); \quad n_t = \sum_{i=1}^n p_{ti};$$

$$\phi_{wt} = \operatorname{norm}_{w \in W} \left( \sum_{i=1}^n [w_i = w] p_{ti} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right).$$

## Быстрое вычисление двунаправленных векторов контекста

Два прохода по тексту — «слева направо» и «справа налево» для вычисления экспоненциальных скользящих средних (ЭСС):

$$\vec{p}(t|i) = \vec{\gamma}_i p(t|w_i) + (1 - \vec{\gamma}_i) \vec{p}(t|i-1), \quad i = 1, \dots, n, \quad \vec{\gamma}_1 = 1$$

$$\bar{p}(t|i) = \bar{\gamma}_i p(t|w_i) + (1 - \bar{\gamma}_i) \bar{p}(t|i+1), \quad i = n, \dots, 1, \quad \bar{\gamma}_n = 1$$

где  $\vec{\gamma}_i$ ,  $\bar{\gamma}_i$  — коэффициенты сглаживания в позиции  $i$

**Основное свойство:** если  $\gamma_i = \gamma$ , то  $\alpha(w_k|i) = \gamma(1 - \gamma)^{|i-k|}$

**Несколько соображений**, как распоряжаться выбором  $\vec{\gamma}_i$ ,  $\bar{\gamma}_i$ :

- $\gamma_i \approx \frac{1}{h}$ , где  $h$  — ширина окна, размер контекста
- $\gamma_i = 1$ , если надо забыть контекст, сменить документ
- $\gamma_i = 0$ , если надо проигнорировать терм
- $\gamma_i$  можно умножать на оценку важности терма

## Онлайновый ЕМ-алгоритм с локализованным Е-шагом

**Вход:** коллекция, число тем  $|T|$ , параметры  $\beta, \vec{\gamma}_i, \tilde{\gamma}_i, \alpha, \delta$ ;

**Выход:** матрица  $\Phi$ , векторы термов документов  $p_{ti}$ ;

инициализация:  $n_{wt} := 0; \tilde{n}_{wt} := 0; n_t := 1; \phi_{wt} := \text{random};$

**для всех** документов  $d \in D$

$$p_{ti} := \text{norm}_t(\phi_{w_i t} n_t), \quad i = 1, \dots, n_d, \quad t \in T;$$

$$\vec{\theta}_{ti} := \vec{\gamma}_i p_{ti} + (1 - \vec{\gamma}_i) \vec{\theta}_{t,i-1}, \quad i = 1, \dots, n_d, \quad \vec{\gamma}_1 = 1, \quad t \in T;$$

$$\hat{\theta}_{ti} := \tilde{\gamma}_i p_{ti} + (1 - \tilde{\gamma}_i) \hat{\theta}_{t,i+1}, \quad i = n_d, \dots, 1, \quad \tilde{\gamma}_{n_d} = 1, \quad t \in T;$$

$$p_{ti} := \text{norm}_t(\phi_{w_i t} (\beta \vec{\theta}_{ti} + (1 - \beta) \hat{\theta}_{ti})), \quad i = 1, \dots, n_d, \quad t \in T;$$

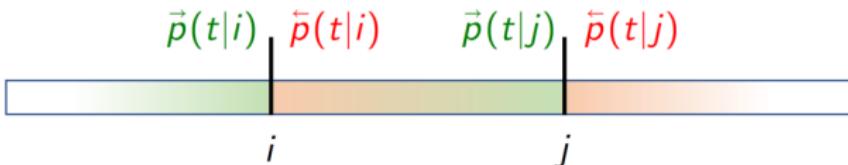
$$\tilde{n}_{w_i t} := \tilde{n}_{w_i t} + p_{ti}; \quad n_t := n_t + p_{ti}, \quad i = 1, \dots, n_d, \quad t \in T;$$

**если** пора обновить матрицу  $\Phi$  **то**

$$n_{wt} := \delta n_{wt} + \alpha \tilde{n}_{wt}; \quad \tilde{n}_{wt} := 0;$$

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

## Использование двунаправленных векторов контекста



Через *дву направленные тематические векторы* определяется:

- $\vec{p}(t|i)$  — тематика левого контекста терма  $w_i$ ;
- $\bar{p}(t|i)$  — тематика правого контекста терма  $w_i$ ;
- $\frac{1}{2}(\vec{p}(t|i) + \bar{p}(t|i))$  — тематика двустороннего контекста  $w_i$ ;
- $p(t|i \dots j) = \frac{1}{2}(\bar{p}(t|i) + \vec{p}(t|j))$  — тематика сегмента  $[i \dots j]$
- $\bar{p}(t|i) \approx \vec{p}(t|j)$  — однородность тематики сегмента  $[i \dots j]$
- $\max_i \|\vec{p}(t|i) - \bar{p}(t|i)\|$  — граница  $i$  между сегментами
- при различных  $\gamma_i$  — короткие и длинные контексты

**Гипотеза:** нет ли полезной аналогии с моделями внимания?

## Напоминание. Модель внимания Query–Key–Value

$q$  — вектор-запрос, трансформируемый в контекстный вектор  $z$ .

Контекст задаётся последовательностью  $n$  значений с ключами:

$V = (v_1, \dots, v_n)$  — векторы-значения;

$K = (k_1, \dots, k_n)$  — векторы-ключи.

Модель внимания — это выпуклая комбинация векторов  $v_i$ , взвешенных по сходству их ключей  $k_i$  с запросом  $q$ :

$$z = \text{Attn}(q, K, V) = \sum_{i=1}^n v_i \text{SoftMax}_i \langle k_i, q \rangle$$

Модель само-внимания (self-attention) трансформирует

$X = (x_1, \dots, x_n)$  — входные бесконтекстные векторы в

$Z = (z_1, \dots, z_n)$  — выходные контекстные векторы:

$$z_i = \text{Attn}(W_q x_i, W_k X, W_v X),$$

где  $W_q, W_k, W_v$  — обучаемые матрицы параметров.

# BERT — Bidirectional Encoder Representations from Transformers

Трансформер BERT — двунаправленный кодировщик текста, предобучаемый для решения различных задач NLP

## Схема преобразования данных:

- $S = (w_1, \dots, w_n)$  — токены входного текста  
 $\downarrow$  обучение векторов (эмбедингов) токенов
- $X = (x_1, \dots, x_n)$  — бесконтекстные векторы токенов  
 $\downarrow$  многократная трансформация через само-внимание
- $Z = (z_1, \dots, z_n)$  — контекстные векторы токенов  
 $\downarrow$  дообучение на конкретную задачу
- $Y$  — разметка текста / классификация и т.п.

---

*Jacob Devlin, Ming-Wei Chang, Kenton Lee, Kristina Toutanova (Google AI Language)*

*BERT: pre-training of deep bidirectional transformers for language understanding. 2019.*

*Dichao Hu. An introductory survey on attention mechanisms in NLP problems. 2018.*

# Архитектура трансформера-кодировщика

1. Добавляются позиционные векторы  $p_i$ :

$$h_i = x_i + p_i, \quad H = (h_1, \dots, h_n) \quad \begin{matrix} d = \dim x_i, p_i, h_i = 512 \\ \dim H = 512 \times n \end{matrix}$$

2. Многомерное само-внимание:  $j = 1, \dots, J = 8$

$$h_i^j = \text{Attn}(W_q^j h_i, W_k^j H, W_v^j H) \quad \begin{matrix} \dim h_i^j = 64 \\ \dim W_q^j, W_k^j, W_v^j = 64 \times 512 \end{matrix}$$

3. Конкатенация (multi-head attention):

$$h'_i = \text{MH}_j(h_i^j) \equiv [h_i^1 \cdots h_i^J] \quad \dim h'_i = 512$$

4. Сквозная связь + нормировка уровня:

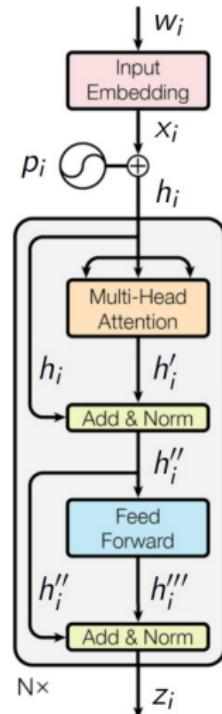
$$h''_i = \text{LN}(h'_i + h_i; \mu_1, \sigma_1) \quad \dim h''_i, \mu_1, \sigma_1 = 512$$

5. Полносвязная 2x-слойная сеть FFN:

$$h'''_i = W_2 \text{ReLU}(W_1 h''_i + b_1) + b_2 \quad \begin{matrix} \dim W_1 = 2048 \times 512 \\ \dim W_2 = 512 \times 2048 \end{matrix}$$

6. Сквозная связь + нормировка уровня:

$$z_i = \text{LN}(h'''_i + h''_i; \mu_2, \sigma_2) \quad \dim z_i, \mu_2, \sigma_2 = 512$$



## Критерий обучения MLM (Masked Language Modeling)

Критерий маскированного языкового моделирования MLM, строится автоматически по текстам (self-supervised learning):

$$\sum_S \sum_{i \in M(S)} \ln p(w_i | i, S, \mathbf{W}) \rightarrow \max_{\mathbf{W}}$$

где  $M(S)$  — подмножество (15%) маскированных токенов из  $S$ ,

$$p(w | i, S, \mathbf{W}) = \text{SoftMax}_w(\mathbf{W}_z z_i(S, \mathbf{W}_T) + b_z)$$

— языковая модель, предсказывающая  $i$ -й токен в тексте  $S$ ;

$z_i(S, \mathbf{W}_T)$  — контекстный вектор  $i$ -го токена текста  $S$  на выходе

Трансформера с параметрами  $\mathbf{W}_T$ ;

$\mathbf{W} = (\mathbf{W}_T, \mathbf{W}_z, b_z)$  — все параметры языковой модели

Jacob Devlin, Ming-Wei Chang, Kenton Lee, Kristina Toutanova (Google AI Language)  
BERT: pre-training of deep bidirectional transformers for language understanding. 2019.

## Трасформер для генерации текста

Добавляется трасформер-декодировщих схожей архитектуры

### Схема преобразования данных:

- $S = (w_1, \dots, w_n)$  — токены входного текста  
 ↓ обучаемая или пред-обученная векторизация
- $X = (x_1, \dots, x_n)$  — бесконтекстные векторы токенов  
 ↓ трансформер-кодировщик
- $Z = (z_1, \dots, z_n)$  — контекстные векторы входных токенов  
 ↓ трансформер-декодировщик
- $Y = (y_1, \dots, y_m)$  — контекстные векторы выходных токенов  
 ↓ генерация токенов по контекстным векторам
- $\tilde{S} = (\tilde{w}_1, \dots, \tilde{w}_m)$  — токены выходного текста

Vaswani et al. (Google) Attention is all you need. 2017.

Tom B. Brown et al. (OpenAI) Language models are few-shot learners. 2020.

# Архитектура трансформера декодировщика

$y_0 = \langle \text{BOS} \rangle$  — эмбединг символа начала;

для всех  $t = 1, 2, \dots$ :

1. Маскирование «данных из будущего»:

$$h_t = y_{t-1} + p_t; \quad H_t = (h_1, \dots, h_t)$$

2. Многомерное самовнимание:

$$h'_t = \text{LN} \circ \text{MH}_j \circ \text{Attn}(W_q^j h_t, W_k^j H_t, W_v^j H_t)$$

3. Многомерное внимание на кодировку  $Z$ :

$$h''_t = \text{LN} \circ \text{MH}_j \circ \text{Attn}(W_q^j h'_t, W_k^j Z, W_v^j Z)$$

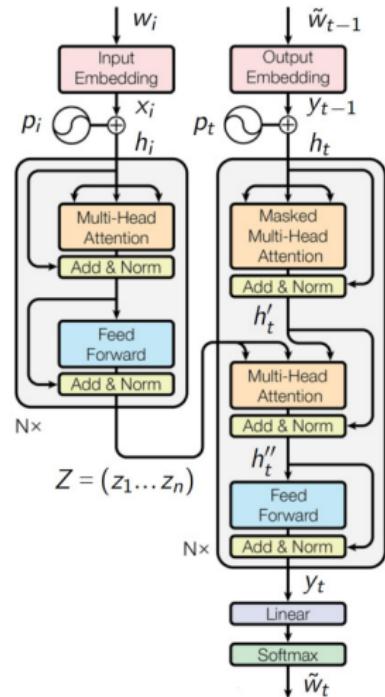
4. Двухслойная полносвязная сеть:

$$y_t = \text{LN} \circ \text{FFN}(h''_t)$$

5. Линейный предсказывающий слой:

$$p(\tilde{w}|t) = \text{SoftMax}(W_y y_t + b_y)$$

генерация  $\tilde{w}_t = \arg \max_{\tilde{w}} p(\tilde{w}|t)$  пока  $\tilde{w}_t \neq \langle \text{EOS} \rangle$



Vaswani et al. (Google) Attention is all you need. 2017.

## Аналогия локализованного Е-шага с моделью само-внимания

Тематический вектор локального контекста на выходе Е-шага:

$$p(t|C_i, w_i) \equiv p_{ti} = \operatorname{norm}_{t \in T}(\phi_{w_i t} \theta_{ti}) = \operatorname{norm}_{t \in T}\left(\sum_{u \in C_i} \phi'_{tu} \phi_{w_i t} \alpha(u|i)\right)$$

Контекстный вектор на выходе модели само-внимания:

$$z_i = \sum_{u \in C_i} W_v x_u \alpha(u|i) = \sum_{u \in C_i} W_v x_u \operatorname{SoftMax}_{u \in C_i} \langle W_q x_i, W_k x_u \rangle$$

### Сходство:

- вектор терма  $w_i$  трансформируется в контекстный вектор
- путём усреднения векторов  $\phi'_{u i}$  из контекста терма  $w_i$ ,
- наиболее (семантически) схожих с вектором терма  $w_i$ .

### Отличия:

- адамарово умножение вектора  $\phi'_{u i}$  на вектор-фильтр  $\phi_{w_i}$ ;
- нет обучаемых матриц  $W_q$ ,  $W_k$ ,  $W_v$  как у модели внимания;
- проецирование итогового вектора на единичный симплекс.

## Аналогия локализованного Е-шага с моделью трансформера

**Один проход документа аналогичен модели внимания:**

- для каждого  $d \in D$ , для каждой позиции  $i = 1, \dots, n_d$  вычисляются 5 тематических векторов, связанных с термом  $w_i$ :

$\phi'_{tw_i} = \text{norm}_t(\phi_{w_i t} n_t)$  — бесконтекстный вектор терма  $w_i$

$\vec{p}(t|i) = \vec{\theta}_{ti}$ ,  $\check{p}(t|i) = \check{\theta}_{ti}$  — векторы левого и правого контекста

$\theta_{ti} = \beta \vec{\theta}_{ti} + (1 - \beta) \check{\theta}_{ti}$  — вектор двустороннего контекста

$p_{ti} = \text{norm}_t(\phi_{w_i t} \theta_{ti})$  — контекстный вектор терма

**Несколько таких проходов аналогичны трансформеру:**

- контекстный вектор терма  $p_{ti} = p(t|i)$  с предыдущего прохода используется вместо его бесконтекстного вектора  $\phi'_{tw_i} = p(t|w_i)$
- $L$  таких итераций аналогичны проходу  $L$  блоков внимания

# Онлайновый ЕМ с многопроходным локализованным Е-шагом

**Вход:** коллекция, число тем  $|T|$ , параметры  $L, \beta, \vec{\gamma}_i, \tilde{\gamma}_i, \alpha, \delta$ ;

**Выход:** матрица  $\Phi$ , векторы термов документов  $p_{ti}$ ;

инициализация:  $n_{wt} := 0; \tilde{n}_{wt} := 0; n_t := 1; \phi_{wt} := \text{random};$

**для всех** документов  $d \in D$

$$p_{ti} := \text{norm}_t(\phi_{wt} n_t);$$

**для всех**  $l = 1, \dots, L$  (аналог  $L$  блоков внимания)

$$\vec{\theta}_{ti} := \vec{\gamma}_i p_{ti} + (1 - \vec{\gamma}_i) \vec{\theta}_{t,i-1}, \quad i = 1, \dots, n_d, \quad \vec{\gamma}_1 = 1;$$

$$\overleftarrow{\theta}_{ti} := \overleftarrow{\gamma}_i p_{ti} + (1 - \overleftarrow{\gamma}_i) \overleftarrow{\theta}_{t,i+1}, \quad i = n_d, \dots, 1, \quad \overleftarrow{\gamma}_{n_d} = 1;$$

$$p_{ti} := \text{norm}_t((\beta \vec{\theta}_{ti} + (1 - \beta) \overleftarrow{\theta}_{ti}) p_{ti} / n_t);$$

$$\tilde{n}_{w,t} := \tilde{n}_{w,t} + p_{ti}; \quad n_t := n_t + p_{ti};$$

**если** пора обновить матрицу  $\Phi$  **то**

$$n_{wt} := \delta n_{wt} + \alpha \tilde{n}_{wt}; \quad \tilde{n}_{wt} := 0;$$

$$\phi_{wt} := \text{norm}_{w \in W} \left( n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right);$$

## Открытые проблемы и постановки задач

- надо ли исключать  $p_{ti}$  позиции  $i$  из контекстов  $\vec{\theta}_{ti}, \hat{\theta}_{ti}$ ?
- какие другие варианты  $\alpha(u|i)$  кроме скользящих средних?
- как выбрать вес  $\beta$  левого контекста?
- правильно ли подставлять  $p_{ti}/n_t$  вместо  $\phi_{w;t}$  на Е-шаге?
- имеет ли смысл увеличивать число проходов  $L$ ?

---

- как (и нужно ли) параметризовать модель внимания?
- как обучать её параметры, разные для разных проходов?
- как (и нужно ли) ввести аналог многих голов внимания?

---

- слишком много эвристических преобразований сделано...  
мы всё ещё решаем исходную оптимизационную задачу?
- действительно ли на Е-шаге можно подвергать  $p(t|d, w_i)$   
всяким модификациям, почему и в каких пределах?

- Работает ли такая тематическая модель внимания?
- Возможны ли другие тематические модели внимания?  
(есть много попыток объединять тематические модели с нейросетевыми моделями языка, attention, transformer)
- Механизмы учёта порядка слов в ARTM:
  - модели  $n$ -грамм, коллокаций, словосочетаний
  - модели сочетаемости пар слов: BitermTM, WNTM
  - линейная однопроходная тематизация документов
  - многопроходная тематизация (аналог трансформера)
  - регуляризация Е-шага
  - модели предложений или сегментоидов
  - тематическая сегментация: модель TopicTiling

---

*Rob Churchill, Lisa Singh. The Evolution of Topic Modeling. 2022*

*He Zhao et al. Topic Modelling Meets Deep Neural Networks: A Survey. 2021*

*Xiaobao Wu, Thong Nguyen, Anh Tuan Luu. A Survey on Neural Topic Models: Methods, Applications, and Challenges. 2023*

*Tian Tian et al. Attention-based Autoencoder Topic Model for Short Texts. 2019*

*Shuangyin Li et al. Recurrent Attentional Topic Model. 2017*

**Задача-минимум:** научиться решать задачи NLP с использованием тематического моделирования в BigARTM

**Задача-максимум:** сделать полезное мини-исследование

виды деятельности	оценка
теоретические задания	$\sum_i X_i$
решение прикладной задачи	5X
обзор по NeuralTM	5X
интеграция ARTM в pyTorch	5X
участие в одном из проектов	10X
работа над открытой проблемой	10X

где  $X$  — оценка за вид деятельности по 5-балльной шкале.

**Итоговая оценка:**  $\min(10, \lfloor \text{score}/5 \rfloor)$  по 10-балльной шкале.

Продолжить исследование Ильи Ирхина:

- Освоить код: [https://github.com/ilirhin/python\\_artm](https://github.com/ilirhin/python_artm)
- Реализовать локализованный Е-шаг

Исследовать зависимость метрик качества от параметров (перплексия, разреженность, различность, когерентность):

- $L$  — число проходов
- $\vec{\gamma}_i, \hat{\gamma}_i$  — длина скользящего среднего
- $\vec{\gamma}_i, \hat{\gamma}_i$  — асимметричность левого и правого контекста
- $\vec{\gamma}_i, \hat{\gamma}_i$  — учёт границ предложений, абзацев, глав
- $\beta$  — баланса левого и правого контекста
- $\alpha, \delta$  — параметры онлайнового ЕМ-алгоритма
- опция «подставлять  $p_{ti}/n_t$  вместо  $\phi_{w_i t}$  на Е-шаге»
- опция «исключать  $p_{ti}$  позиции  $i$  из контекстов  $\vec{\theta}_{ti}, \hat{\theta}_{ti}$ »

# Теоретическое задание к лекции №1

Упражнения на принцип максимума правдоподобия:

1. Униграммная модель документов:  $p(w|d) = \xi_{dw}$

Найти параметры модели  $\xi_{dw}$ .

2. Униграммная модель коллекции:  $p(w|d) = \xi_w$  для всех  $d$

Найти параметры модели  $\xi_w$ .

Подсказка: применить условия ККТ или основную лемму.

3. (более творческое задание)

Предложите модель, определяющую роли слов в текстах:

- тематические слова
- специфичные слова документа (шум)
- слова общей лексики (фон)

Подсказка 1: искать распределение ролей слов  $p(r|w)$ ,  $r \in \{\text{т, ш, ф}\}$ .

Подсказка 2: можно разреживать  $p(r|w)$  для жёсткого определения ролей.

Подсказка 3: можно использовать документную частоту слов.

## Теоретическое задание к лекции №2

4. Заменим  $\log$  другой монотонно возрастающей функцией  $\mu$ :

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \mu \left( \sum_{t \in T} \phi_{wt} \theta_{td} \right) + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

Как изменится ЕМ-алгоритм? Возможно ли подобрать функцию  $\mu$  так, чтобы сократился объём вычислений?

5. Заменим  $\log$  монотонно возрастающей функцией  $\mu$  в регуляризаторе сглаживания–разреживания (модель LDA):

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

Как изменится М-шаг и воздействие регуляризатора на модель?

6. Какому регуляризатору соответствует формула М-шага

$$\phi_{wt} = \operatorname{norm}_w(n_{wt} [n_{wt} > \gamma n_t])$$

Аналитик построил тематическую модель  $\Phi^0, \Theta^0$  и отметил среди столбцов матрицы  $\Phi^0$  темы двух типов: удачные  $T_+ \subset T$  и неудачные  $T_- \subset T$ .

Теперь он хочет построить модель ещё раз так, чтобы

- удачные темы остались в матрице  $\Phi$ ;
- остальные темы построились по-другому и были не похожи на каждую из неудачных тем  $t \in T_-$ .

7. Предложите регуляризаторы для этого.
8. Не получится ли так, что новые темы будут отдаляться от суммы неудачных тем  $\sum_{t \in T_-} \phi_{wt}^0$  вместо того, чтобы отдаляться от каждой из неудачных тем по отдельности? Почему это плохо и как этого избежать?
9. Предложите способ инициализации  $\Phi$  для новой модели.

**10.** Для иерархической тематической модели с рег.  $R(\Phi, \Psi)$  предложите способ разреживания матрицы связей

$\Psi = (p(s|t))$ , гарантирующий, что

- 1) у каждой родительской темы будет хотя бы одна дочерняя;
- 2) у каждой дочерней темы будет хотя бы одна родительская.

Подсказка: можно придумывать критерий регуляризации, а можно — формулу М-шага для матрицы  $\Psi$ .

**11.** Предложите способ гарантировать, что если родительская тема  $t$  получает только одну дочернюю  $s$ , то она переходит в неё целиком и как распределение:  $p(w|s) = p(w|t)$ .

**12.** Предложите способ согласования вероятностных смесей  $p(w|t) \approx \sum_{s \in S} p(w|s)p(s|t)$  и  $p(t|d) \approx \sum_{s \in S} p(t|s)p(s|d)$  с учётом тождества  $p(s|t)p(t) = p(t|s)p(s)$ .

- 15.** Выведите EM-алгоритм с локализованным E-шагом (слайд 15) для локализованной тематической модели. Какие переменные удобнее оставить в модели,  $\phi_{wt}$  или  $\phi'_{tw}$ ?
- 16.** Предложите параметризацию для тематической модели внимания (слайд 25). Используя «основную лемму», получите уравнения для новых параметров модели.