

# Итеративный подбор коэффициентов регуляризации тематических моделей

Захаренков Антон

Московский физико-технический институт  
Факультет управления и прикладной математики  
Кафедра интеллектуальных систем

Научный руководитель  
профессор РАН, д.ф.-м.н.  
К. В. Воронцов

28 июня 2018

## Цель

Разработать метод последовательного подбора коэффициентов регуляризации тематических моделей.

## Проблема

Различные комбинации регуляризаторов могут значительно улучшить многие внутренние метрики модели тематического моделирования. Подбор коэффициентов перед ними на данный момент эвристика.

## Предложенный подход

Применяются методы безградиентной оптимизации, байесовской оптимизации и машинного обучения для автоматического подбора коэффициентов регуляризации в модели АРТМ.

$$L(\Phi, \Theta) = \ln \prod_{d \in D} \prod_{w \in \mathcal{W}} P(w | d)^{n_{dw}} = \sum_{d \in D} \sum_{w \in \mathcal{W}} n_{dw} \ln \sum_{t \in T} \varphi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta}$$

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

$$R(\Phi, \Theta) = \sum_{i=1}^r \hat{\tau}_i R_i(\Phi, \Theta)$$

$$L(\Phi, \Theta) + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

## Сглаживающий регуляризатор

$$R(\Phi, \Theta) = \beta_0 \sum_{t \in T} \sum_{w \in W} \beta_w \ln \varphi_{wt} + \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_t \ln \theta_{td} \rightarrow \max$$

## Разреживающий регуляризатор

$$R(\Phi, \Theta) = -\beta_0 \sum_{t \in T} \sum_{w \in W} \beta_w \ln \varphi_{wt} - \alpha_0 \sum_{d \in D} \sum_{t \in T} \alpha_t \ln \theta_{td} \rightarrow \max$$

## Декоррелирующий регуляризатор

$$R(\Phi, \Theta) = \frac{\tau}{2} \sum_{t \in T} \sum_{s \in T \setminus t} \text{cov}(\varphi_t, \varphi_s) \rightarrow \max$$

$$\text{cov}(\varphi_t, \varphi_s) = \sum_{w \in W} \varphi_{wt} \varphi_{ws}$$

- Перплексия

$$\mathcal{P}(D; p) = \exp \left( -\frac{1}{n} \sum_{d \in D} \sum_{w \in W} n_{dw} \ln P(w | d) \right)$$

- Когерентность

$$\text{Coher}(t) = \frac{2}{k(k-1)} \sum_{i=1}^{k-1} \sum_{j=1}^k \text{PMI}(w_i; w_j)$$

- Разреженность матриц

- Характеристики ядер тем

- $\text{purity}_t = \sum_{w \in W_t} P(w | t)$  — чистота темы
- $\text{contrast}_t = \frac{1}{|W_t|} \sum_{w \in W_t} P(t | w)$  — контрастность темы
- $\text{kernel}_t \text{ size} = |W_t|$  — размер ядра

## Задача оптимизации

$$R(\Phi) = \sum_{i=1}^r \bar{\tau}_i R_i(\Phi), \quad L(\Phi) + R(\Phi) \rightarrow \max_{\Phi}$$

Для решения данной оптимизационной задачи применяется итерационный процесс, порождающий последовательность приближений  $\Phi^l$ ,  $l = 0, 1, \dots$ , где используется правило

$$\Phi^{l+1} = F_l(\Phi^l, \bar{\tau}^l, D_{b(l)})$$

с вектором коэффициентов регуляризации  $\bar{\tau}^l := \{\tau_i^l\}_{i=1}^n$ .

Последовательность векторов  $\bar{\tau}^l$ ,  $l = 0, 1, \dots$ , называется *траекторией регуляризации*.

---

**Algorithm** Адаптивное управление траекторией регуляризации

---

**Вход:** коллекция документов  $D \equiv \{D_b\}_{b=1}^B$ ,  $\Phi^0$ ,  $\vec{\tau}^0$ ;

**Выход:** оптимальный вектор коэффициентов регуляризации  $\vec{\tau}^*$ ;  
для итераций  $l = 0, 1, \dots$ :

$D_{b(l)} :=$  *взять следующую пачку из  $\{D_b\}_{b=1}^B$ ;*

$\Phi^{l+1} := F_l(\Phi^l, \vec{\tau}^l, D_{b(l)});$

$\vec{Q}^{l+1} := \vec{Q}(x^{l+1});$

$\vec{\tau}^{l+1} :=$  *выбрать следующий  $\vec{\tau}(\vec{Q}^{l+1}, \vec{\tau}^l, \Phi^{l+1}, D_{b(l)});$*

---

- Показатели качества  $Q_j$ , определённые значения которых требуется достичь, могут быть лишь косвенно связаны с регуляризаторами  $R_j$
- Исходная функция  $a : \vec{r} \rightarrow \vec{Q}$  может являться трудновычислимой, недифференцируемой и даже негладкой из-за сложных регуляризаторов
- Точка в пространстве показателей качества  $\vec{Q}$  определяется неоднозначно, с учётом погрешности  $\varepsilon$ , которую даёт тематическая модель АРТМ, производящая разложение на матрицы  $\Phi$  и  $\Theta$  при обработке конечной пачки документов  $D_{b(l)}$
- Коэффициенты регуляризации  $\vec{r}_i$  могут входить в противоречия и требовать изменений в разные стороны



- **Случайный поиск по сетке**



Метод случайного поиска предполагает случайный выбор вектора коэффициентов регуляризации  $\vec{r}$  из фиксированной сетки, которая задаётся экспертно.

- **Симплекс метод Nelder—Mead**

Данный метод заключается в построении симплекса из  $n + 1$  точки в  $n$ -мерном пространстве значений. Далее текущий симплекс предлагается итеративно деформировать и перемещать в поисках экстремума путём замены одной из точек. Деформации и перемещения обеспечиваются функциями отражения, сжатия и растяжения.

## ● Tree-structured Parzen Estimators

TPE принимает на вход иерархическое пространство поиска с априорными вероятностями, и на каждом шаге уточняет распределения «хороших» и «плохих» параметров, основываясь на значениях целевой метрики. В начале каждой итерации выбирается точка, которая наиболее вероятно будет относиться к группе «хороших» точек, и наименее вероятно «плохих».



- **Множественная регрессия**

В ходе итерационного процесса накапливается обучающая выборка пар векторов  $(\vec{\tau}^k, \vec{Q}^k)$ , где вектор  $\vec{Q}^k$  — это значения показателей качества, полученные при построении АРТМ модели с коэффициентами регуляризации  $\vec{\tau}^k$ .

Если зависимость  $\vec{Q}(\vec{\tau})$  удалось хорошо восстановить, то в качестве следующего вектора  $\vec{\tau}$  можно брать тот, для которого предсказанная величина  $\vec{Q}(\vec{\tau})$  будет ближайшей к  $\vec{Q}^*$ .

При восстановлении регрессионной зависимости существуют следующие сложности.

Во-первых, изначально выборка  $\{(\vec{\tau}^k, \vec{Q}^k)\}_{k=0}^N$  пуста, и не получится сразу хорошо предсказывать вектор показателей качества для векторов-кандидатов  $\vec{\tau}^l$ ,  $l = 0, 1, \dots, L$ .

Первые значения можно:

- брать случайными
- сэмплировать из распределения, смоделированного TPE

Во-вторых, достижение окрестности  $\vec{Q}^*$  может оказаться трудной задачей, а регрессионная зависимость может строиться по обучающей выборке, которая находится далеко от целевых значений  $(\vec{\tau}^*, \vec{Q}^*)$ .


Для решения этой проблемы предлагается чередовать *исследовательские* и *максимизирующие* шаги. На этапе исследования предлагается выбирать произвольный вектор  $\vec{\tau}^l$  (либо сэмплировать из TPE), а на этапе максимизации делать попытку приблизиться к оптимуму.

## Цели:

- применить предложенные алгоритмы к реальным данным,
- сравнить полученные результаты друг с другом с точки зрения взвешенной метрики, а так же отдельных метрик

## Данные:


- **postnauka** - [postnauka.ru](http://postnauka.ru)  
 $|D| = 3446$   $|W| = 35531$ ;
- **elementy** - [elementy.ru](http://elementy.ru)  
 $|D| = 2397$   $|W| = 54349$ ;




Итерации алгоритма

Nelder-Mead сходится к локальному оптимуму, GB-TPE продолжает исследования, периодически достигая более оптимальных значений.


# Элементы. Оффлайн эксперимент.




Random



Nelder-Mead




GB-Random




GB-TPE

Рис.: Изменение внутренних метрик качества модели






Итерации по группам






Итерации по группам



Итерации по группам

# Элементы. Онлайн эксперимент.



- 1 Проведены вычислительные эксперименты на реальных данных;
- 2 Проверены новые и существующие методы адаптивного подбора траектории регуляризации в тематическом моделировании
- 3 Показано, что новый алгоритм GB-TPE находит точки не хуже, чем Nelder-Mead, но ведет себя более «исследовательски».