

# Построение тематической классификации коллекции документов с неизвестным числом тем

С. Ю. Лобастов

24 июня 2013 г.

Научный руководитель: К. В. Воронцов

# Постановка задачи

**Дано:**

$D = \|n_{dw}\|$  — коллекция текстовых документов

$W$  — словарь

**Предположение:**

- Существует распределение  $p(d, w, t)$  на  $\mathcal{D} \times W \times \mathcal{T}$
- $\Phi = \|p(w|t)\| \in Mat_{|W| \times |\mathcal{T}|}$ ,    $\Theta = \|p(t|d)\| \in Mat_{|\mathcal{T}| \times |\mathcal{D}|}$

$$D = \Phi \times \Theta$$

**Найти:**

- Число тем  $|\mathcal{T}|$
- Параметры  $\Phi$  и  $\Theta$

# Распределение Дирихле

$\vec{\phi}_t = (\phi_{1t}, \dots, \phi_{|W|t})$  — параметры мультиномиального распределения слов в теме  $t$ .

**Предположение:**  $\exists \alpha : \forall t \in \mathcal{T} \quad \vec{\phi}_t \sim Dir(\alpha)$ , где  $Dir(\alpha)$  — распределение Дирихле:

**Свойства:**

- $\sum_{w \in W} \phi_{wk} = 1$
- $\phi_{wk} \geq 0 \quad \forall w \in W$





Рис.: Плотность распределения Дирихле

## Порождающие модели

1. LDA. Каждое слово  $x_{dw}$  принадлежит ровно одной теме  $t_{dw}$ . Число тем  $|\mathcal{T}|$  задано.

$$x_{dw} \longrightarrow t_{dw} = t_{old} \rightarrow w \sim Dir(\vec{\phi}_t)$$

2. HDP. Слова разбиты на группы, темы определяются для них.



# Семплирование

1. LDA. Необходимо семплировать темы для слов.
  - $p(t|w, d) \sim \hat{p}(t|d)\hat{p}(w|t)$
2. HDP. Необходимо семплировать группы для слов и темы для групп.
  - $p(g|w, d) \sim \hat{p}(t_{dg}|d)\hat{p}(w|t_{dg})$
  - $p(t|g, d) \sim \hat{p}(g|t)\hat{p}(t|d)$

# Анализ HDP

docs count: 50 word count: 200 words in doc: 50  $\alpha = 2.0$ ;  $\beta = 10$ ;  
 $\gamma = 0.01$ ; Истинное число тем — 38.




Рис.: Зависимость числа тем от номера итерации

## Анализ HDP. Устойчивость.

docs count: 50 word count: 200 words in doc: 50  $\alpha = 2.0$ ;  $\beta = 10$ ;  
 $\gamma = 0.01$ ;

Истинное число тем — 38; число экспериментов — 30.




Рис.: Число тем

Дисперсия результатов HDP.

## Устойчивость по параметрам

docs count: 50 word count: 200 words in doc: 50  $\alpha = 2.0$ ;  $\beta = 10$ ;  
 $\gamma = 0.01$ ;




Рис.: Зависимость числа тем, определенных алгоритмом HDP, от параметра  $\alpha$




Рис.: Зависимость числа тем, определенных алгоритмом HDP, от параметра  $\beta$

# Запуск на разреженной коллекции

Параметры генерации:  $\alpha = 0.01$ ;  $\beta = 0.01$ ; Истинное число тем — 30.




Рис.: Расстояния между истинными и найденными темами




Рис.: Число слов в найденных темах

# Запуск на неразреженной коллекции

Параметры генерации:  $\alpha = 0.1$ ;  $\beta = 0.1$ ; Истинное число тем — 10.




Рис.: Расстояния между истинными и найденными темами




Рис.: Число слов в найденных темах

## Предположение

Параметр распределения Дирихле  $\alpha$  существенно влияет на результат: чем он больше, тем сильнее могут различаться профили темы в разных документах.

**Идея:** будем увеличивать этот параметр на каждой итерации.

# Результат

Параметры генерации:  $\alpha = 0.1$ ;  $\beta = 0.1$ ; Истинное число тем — 10.




Рис.: Расстояния между истинными и найденными темами




Рис.: Число слов в найденных темах

# Сходимость




Рис.: Зависимость числа тем от номера итерации

## Выводы

- Алгоритм HDP способен автоматически определять число тем, содержащихся в коллекции документов.
- Однако это вероятностный алгоритм, и дисперсия его результатов велика.
- Предложен метод решения этой проблемы путем подбора параметров.