

Использование контекстной документной кластеризации для улучшения качества построения тематических моделей

А. В. Гринчук

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

Научный руководитель: д.ф.-м.н. К. В. Воронцов

Дано:

- D — множество документов коллекции,
- W — множество слов коллекции (словарь коллекции),
- n_{dw} — число вхождений слова $w \in W$ в документ $d \in D$,
- $\hat{p}(w|d) = \frac{n_{wd}}{n_d}$ — частота встречаемости слова в документе,
- $F = \|\hat{p}(w|d)\|$ — представление коллекции в виде матрицы.

Задача:

Определить множество тем T и представить матрицу F в виде

$$F_{w \times D} \approx \Phi_{w \times T} \cdot \Theta_{T \times D}.$$

$\Phi = \|p(w|t)\|$ — матрица распределения слов по темам,

$\Theta = \|p(t|d)\|$ — матрица распределения тем по документам.

- ① Неединственность матричного разложения:

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

Способ решения проблемы: регуляризация

- ② Сходимость решения к локальным экстремумам.

Способы решения проблемы:

- мультистарт
- выбивание из локальных экстремумов (jogging of weights)
- выбор начального приближения

- Dobrynin, V., Patterson, D., Rooney, N. Contextual document clustering. In Proceedings of the 26th European Conference on Information Retrieval Research, LNCS 2997, pp. 167-180. Berlin/Heidelberg: Springer, 2004.
- Chuang, J., Gupta, S., Manning, C. D., Heer, J. Topic Model Diagnostics: Assessing Domain Relevance via Topical Alignment. ICML(3), JMLR.org, pp. 612-620, 2013.
- Potapenko, A., Vorontsov, K. Additive Regularization of Topic Models. Machine Learning Journal, Special Issue „Data Analysis and Intelligent Optimization“, Springer, 2014.

Цель работы

- Предложить интерпретируемый подход к выбору тем в тематических моделях.
- Разработать метод, позволяющий находить хорошее начальное приближение матриц Φ и Θ .
- Добиться того, чтобы полученная из начального приближения тематическая модель была лучше моделей, инициализируемых стандартными методами.

Базовые определения

Определение 1

Контекстом слова w называется дискретное распределение $p(u|w)$ на W . Это вероятностное распределение слов, которые встречаются вместе со словом w в документах коллекции.

Определение 2

Документной частотой называется число документов коллекции, в которых данное слово встретилось

$$N_w = |D_w|, \quad D_w = \{d \in D : n_{dw} > 0\}.$$

Определение 3

Энтропией слова w называется энтропия его контекста:

$$H(w) = - \sum_{u \in W} p(u|w) \log p(u|w).$$

Предположение: каждая тема содержит уникальные слова (термины), которые её хорошо определяют. Вместе они встречаются гораздо чаще, чем по отдельности и редко встречаются со словами из других тем.

Такие слова назовём **узкими контекстами**.

Идея:

Отобрать все узкие контексты и кластеризовать их. После использовать полученные распределения в качестве столбцов матрицы Φ при её инициализации.

Пусть $W(D_w) = \{u \in W : n_{du} > 0, d \in D_w\}$ — множество всех слов, которые встречаются в документах коллекции вместе со словом w . Максимальное значение энтропии достигается, когда контекст слова является равномерным распределением и равно

$$H_{max}(w) = \log |W(D_w)|.$$

Чем меньше энтропия слова, тем меньше слов составляет его контекст. Такие слова, как правило, и образуют темы, а, значит, могут считаться узкими контекстами.

Выделение узких контекстов

По закону Хипса, словарь коллекции имеет размер Kn^β , где n — это размер всей коллекции в словах, а K и $\beta < 1$ — некоторые постоянные. Пусть k — средний размер в словах документов из W_d . Тогда

$$\begin{aligned} H(w) &\leq H_{\max}(w) = \log |W(D_w)| = \log K(k \cdot N_w)^\beta = \\ &= \log K + \beta \log k + \beta \log(N_w) = C + \beta \log N_w. \end{aligned}$$

Как видно, энтропия зависит от документной частоты. Поэтому в качестве узких контекстов будем выбирать слова с минимальной энтропией для каждого значения документной частоты.

Алгоритм контекстной кластеризации слов

Выделение узких контекстов

Вход: коллекция текстовых документов

Выход: множество узких контекстов

Метод:

- сегментация слов по частоте N_w [Добрынин, 2004]
- квантильная регрессия

Инициализация тематической модели

Вход: множество узких контекстов

Выход: матрицы Φ и Θ

Метод:

- кластеризация методом k-средних
- расстояние Хеллингера

Вычислительный эксперимент: отбор слов




Рис.: Отбор узких контекстов классической CDC для коллекции NIPS

Вычислительный эксперимент: отбор слов




Рис.: Отбор узких контекстов квантильной регрессией для NIPS

- В эксперименте использовалась русскоязычная коллекция статей конференции ММРО-ИОИ.
- Встречающиеся вместе считались слова, которые встретились хотя бы раз в одном и том же документе.
- Для отбора слов применялась квантильная регрессия с квантилью $\tau = 0.05$.
- Тематическая модель строилась в библиотеке BigARTM (www.bigartm.org) без использования регуляризаторов.

Вычислительный эксперимент: перплексия




Рис.: Сравнение прплексии для различных инициализаций

Вычислительный эксперимент: интерпретируемость

Тема 9*

изображение(0.136)
преобразование(0.020)
форма(0.015)
яркость(0.013)
пиксель(0.008)
координата(0.008)
размер(0.007)
плоскость(0.007)
фрагмент(0.007)
обработка(0.006)

Тема 10

точка(0.026)
распознавание(0.010)
трёхмерный(0.010)
объект(0.010)
плоскость(0.010)
фильтр(0.009)
координата(0.009)
изображение(0.009)
поверхность(0.008)
задача(0.008)

Тема 29

изображение(0.081)
преобразование(0.021)
точка(0.017)
объект(0.014)
метод(0.013)
контур(0.011)
быть(0.011)
описание(0.010)
область(0.010)
являться(0.008)

Тема 9* — тема в модели без высокочастотных слов

Вычислительный эксперимент: интерпретируемость

Тема 19*

ладонь(0.016)
человек(0.015)
идентификация(0.014)
палец(0.014)
эксперт(0.008)
движение(0.008)
изображение(0.008)
база(0.007)
экспертный(0.007)
лицо(0.007)

Тема 12

изображение(0.043)
алгоритм(0.013)
который(0.011)
объект(0.011)
классификатор(0.011)
ошибка(0.009)
быть(0.009)
ладонь(0.009)
представление(0.009)
палец(0.009)

- Усовершенствован критерий отбора слов в методе контекстной документной кластеризации с помощью квантильной регрессии.
- Показано, что кластеризация локальных контекстов является хорошей инициализацией для тематических моделей, которая ведёт к лучшим локальным максимумам правдоподобия.
- Показано, что удаления слов с большими значениями документной частоты улучшают интерпретируемость модели.