

Использование тематических моделей в извлечении однословных терминов

Нокель Михаил Алексеевич
Лукашевич Наталья Валентиновна

Московский Государственный Университет им. М.В. Ломоносова

План доклада

- Постановка задачи
- Коллекции текстов для экспериментов
- Статистические тематические модели
 - Основанные на методах кластеризации текстов
 - Вероятностные тематические модели
- Эксперименты
 - Выбор лучшей тематической модели
 - Сравнение тематических признаков с традиционными
- Заключение

Определение термина

Определение

Термин – слово (или сочетание слов), являющееся точным обозначением определённого понятия какой-либо специальной области науки, техники, искусства, общественной жизни и т.п.

Примеры терминов (из банковской области):

- Банк
- Ипотечный кредит
- Кредит

Определение

Извлечение терминов – задача в автоматической обработке текстов, заключающаяся в извлечении терминов из текстов некоторой конкретной предметной области

Автоматическое извлечение терминов

- *Приложения:*
 - Разработка тезаурусов, рубрикаторов
 - Использование в приложениях информационного поиска
 - Машинный перевод
 - Синтаксический анализ
- Эксперты используют множество принципов для определения терминов → необходимо использовать множество различных признаков для автоматического извлечения терминов
- *Текущий тренд исследований* – применение методов машинного обучения для комбинирования признаков:
 - (Pecina and Schlesinger, 2006)
 - (Foo and Merkel, 2010)
 - (Loukachevitch, 2012)

Извлечение однословных терминов

- Большинство работ посвящено извлечению многословных терминов
 - Более 85% терминов – многословные
- Мы рассматриваем *однословные* термины
 - Данная задача более трудоёмка
 - Нет внутренней структуры термина
 - Широко известные ассоциативные меры (Mutual Information, t-score и др.) не применимы
 - Одной статистики недостаточно для распознавания таких терминов в текстах
 - Необходима информация о контексте употребления

Традиционные признаки

- Основанные на частотности
 - Идея: термины встречаются чаще остальных слов
 - TF , DF , $TFIDF$, $TFRIDF$ и *Domain Consensus*

- Использующие контрастную коллекцию
 - Идея: частотности терминов в целевой и контрастной коллекциях сильно различаются
 - *Weirdness*, $TFIDF$, $KFIDF$, *Loglikelihood* и др.

- Контекстные
 - Соединяют информацию о частотности слов с данными о контексте их употребления
 - $C\text{-}Value$, $NC\text{-}Value$, *Sum3*, *Insideness* и др.

- Прочие
 - Номер позиции первого вхождения в документы
 - Типы слов-кандидатов (сущ. или прил.)
 - Сущ. в именительном падеже (“подлежащие”) и др.

Основная задача

Предположение

Большинство терминов относятся к той или иной подтеме предметной области → выделение таких подтем способно улучшить качество автоматического извлечения терминов

- Необходимо исследовать возможность использования тематической информации для повышения качества извлечения однословных терминов независимо от языка и от предметной области
 - Исследовать статистические тематические модели с точки зрения задачи извлечения однословных терминов для выбора лучшей
 - Сравнить признаки, посчитанные для лучшей тематической модели, с остальными признаками для определения вклада тематической информации

Процесс извлечения терминов



Коллекции текстов для экспериментов

- Коллекции текстов:

- Русскоязычные тексты из электронных банковских журналов: *Аудитор*, *Банки и Технологии*, *РБК* и др.
 - 10422 документа (\approx 15.5 млн слов)
- Английская часть корпуса *Europarl*:
 - 9673 документа (\approx 54 млн слов)

- “Золотые стандарты”:

- Для русского языка – банковский тезаурус, разработанный вручную для ЦБ РФ:
 - \approx 15000 терминов
- Для английского языка – официальный тезаурус Евросоюза *Eurovoc*:
 - 15161 термин

- Подтверждение терминов: слово-кандидат считается термином, если оно есть в тезаурусе

Статистические тематические модели

Определение

Статистическая тематическая модель – модель, на основе статистических методов определяющая, к каким подтемам относится каждый документ и какие слова образуют каждую подтему

Определение

Подтема – список часто встречающихся рядом друг с другом слов, упорядоченный по убыванию степени принадлежности ему

Подтема 1	Подтема 2	Подтема 3
Банкнота	Обучение	Германия
Оффшорный	Студент	Франция
Счетчик	Учебный	Евро
Купюра	Вуз	Европейский

Виды статистических тематических моделей

- Тематические модели на методах кластеризации текстов
- Вероятностные тематические модели

- Основываются на методах жесткой кластеризации
 - Каждый документ – разреженный вектор в пространстве слов большой размерности
- В конце кластеризации каждый кластер – один большой документ для вычисления вероятностей слов:

$$P(w|t) = \frac{TF(w|t)}{\sum_w TF(w|t)}$$

- Общие шаги в процессе кластеризации:
 - Предобработка документов (фильтрация слов)
 - Преобразование документов в вектор слов
 - Расчет расстояния между документами
 - Схема взвешивания слов:


$$TFIDF(w|d) = TF(w|d) \times \max \left(0, \log \frac{N - DF(w)}{DF(w)} \right)$$

- Кластеризация документов

Тематические модели на методах кластеризации


К-Средних

- К-Средних
- Сферический К-Средних




Агломеративная кластеризация

- Single-link
- Complete-link
- Average-link



Неотрицательная матричная факторизация (NMF)

- NMF Euclidean
- NMF KL-Divergence



Вероятностные тематические модели

- Каждый документ – смесь подтем
- Каждая подтема – вероятностное распределение над словами
- Вероятностная модель порождения документа d :

$$P(w|d) = \sum_t P(w|t)P(t|d)$$

- Процесс порождения слов:

Для всех документов $d \in D$:


Для всех слов $w \in d$:

Выбрать тему t из $p(t|d)$

Выбрать слово w из $p(w|t)$

Вероятностные тематические модели

- Метод вероятностного латентного семантического моделирования (*PLSA*)
 - (Ding, Li, Peng, 2008) показали, что NMF, минимизирующий расстояние Кульбака-Лейблера, эквивалентен PLSA
- Латентное размещение Дирихле (*LDA*)



- Приближённые способы настройки параметров:
 - *LDA VB* – оригинальная реализация Blei
 - *LDA Gibbs* – реализация LDAGibbs++

Признаки, использующие тематическую информацию

Предположение

В начале списков, образующих подтемы, с большой вероятностью находятся термины

Признак	Формула
Частотность (TF)	$\sum_t P(w t)$
TFIDF	$TF(w) \times \log \frac{K}{DF(w)}$
Domain Consensus (DC)	$-\sum_t P(w t) \times \log P(w t)$
Maximum TF	$\max_t P(w t)$
Term Score (TS)	$\sum_t TS(w t),$ $TS(w t) = P(w t) \times \log \frac{P(w t)}{\left(\prod_t P(w t)\right)^{\frac{1}{K}}}$
TS-IDF	$TS(w) \times \log \frac{K}{DF(w)}$
Maximum TS	$\max_t TS(w t)$

Baseline и метрика оценки качества


- Baseline – “тематическая модель”
 - Не выделяет никаких подтем
 - Каждый документ – отдельная подтема
- Метрика оценки качества – Средняя Точность (AvP):

$$AvP(n) = \frac{\sum_{k=1}^n Precision(k)}{number\ of\ terms}$$

- Разное число подтем (50, 100 и 150) на качество извлечения терминов никак не повлияло → число подтем равно 100
- Все признаки рассчитывались для 5000 самых частотных слов

Выбор лучшей тематической модели

- Комбинирование тематических признаков для каждой модели логистической регрессией (библиотека Weka)
- Четырёхкратная кросс-проверка



- Вывод: лучшая тематическая модель – NMF KL

Сравнение тематических признаков с традиционными

- Традиционные признаки
 - Основанные на частотности
 - TF , DF , $TFIDF$, $TFRIDF$ и *Domain Consensus*
 - Использующие контрастную коллекцию
 - Корпус русского языка
 - Британский национальный корпус
 - *Weirdness*, $TFIDF$, $KFIDF$, *Loglikelihood* и др.
 - Контекстные
 - *C-Value*, *NC-Value*, *Sum3*, *Insideness* и др.
 - Прочие
 - Номер позиции первого вхождения в документы
 - Сущ. в именительном падеже (“подлежащие”) и др.
- Тематические признаки (для модели NMF KL)
 - TF , $TFIDF$, *Domain Consensus*, *Maximum TF*, TS , $TS-IDF$, *Maximum TS*

Лучшие признаки

- Русская банковская коллекция:

Группа признаков	Лучший признак	AvP
Основанные на частотности	<i>TFRIDF</i>	41.1
Использующие контрастную коллекцию	<i>LogLikelihood</i>	36.9
Контекстные	<i>Sum3</i>	37.4
Тематические	Term Score	48.9

- Английская коллекция Europarl:

Группа признаков	Лучший признак	AvP
Основанные на частотности	<i>TFRIDF</i> для подлежащих	38.5
Использующие контрастную коллекцию	<i>TFIDF</i> для подлежащих	34.2
Контекстные	<i>C-Value</i>	31.3
Тематические	Term Score	44.5

- Вывод: независимо от языка и предметной области лучшие признаки – тематические (+19% и +15% AvP по сравнению с остальными)


Определение вклада тематических признаков

- Модель с тематическими признаками (7 baseline признаков + 7 признаков, посчитанных для NMF KL) vs. модель без них
- Комбинирование признаков – методом логистической регрессии (библиотека Weka)
- Результаты:

Коллекция	Средняя точность	
	Без тематических признаков	С тематическими признаками
Русская	54.6	56.3
Английская	50.4	51.4

- Вывод: тематические модели вносят дополнительную информацию в процесс автоматического извлечения терминов

Графики средней точности



Примеры извлечённых терминов

- Модель с тематическими признаками
- Подтверждённые термины выделены *цветом*

№	Русский корпус	Английский корпус
1	<i>Банковский</i>	Member
2	<i>Банк</i>	Minute
3	Год	<i>Amendment</i>
4	<i>РФ</i>	<i>Document</i>
5	<i>Кредитный</i>	EU
6	<i>Налоговый</i>	President
7	<i>Кредит</i>	<i>People</i>
8	<i>Пенсионный</i>	<i>Directive</i>
9	Средство	Year
10	Клиент	Question

Заключение

- Предложено использовать тематические модели для извлечения терминов
- На основе тематических моделей предложено несколько модификаций известных признаков для ранжирования слов-кандидатов по степени их терминологичности
- Экспериментально показано, что использование тематической информации способно улучшить качество автоматического извлечения однословных терминов независимо от предметной области и языка

Спасибо за внимание!

Вопросы?

Традиционные признаки

- Основанные на частотности:

$$TFIDF(w) = TF(w) \times \log \frac{|D|}{DF(w)}$$

$$TFRIDF(w) = TF(w) \times \left(\log \frac{|D|}{DF(w)} - \left(-\log \left(1 - e^{-\frac{TF(w)}{|D|}} \right) \right) \right)$$

$$DC(w) = - \sum_{d \in D} (TF(w|d) \times \log TF(w|d))$$

- Использующие контрастную коллекцию:

$$Weirdness(w) = \left(\frac{TF_t(w)}{|W_t|} \right) / \left(\frac{TF_r(w)}{|W_r|} \right)$$

$$KFIDF(w) = DF_t(w) \times \left(\frac{2}{|D|_w} + 1 \right)$$

где $|D|_w = 1$, если слово содержится в контрастной коллекции и $|D|_w = 2$ иначе

Традиционные признаки

- Контекстные:

$$C - Value(w) = TF(w) - \frac{\sum_{p \in P_w} TF(p)}{|P_w|}$$

где P_w – множество объемлющих фраз, содержащих слово w

$$SumN(w) = \frac{\sum_{p \in P_w^N} TF(p)}{N}$$

где P_w^N – множество N самых частотных объемлющих фраз, содержащих слово w

$$Insideness(w) = \frac{F_{max}}{TF_t(w)}$$

где F_{max} – максимальная частота объемлющей фразы, содержащей слово w