

Оценивание качества выделения терминов в задаче классификации текстовых документов

Сухарева Анжелика

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

Московский физико-технический институт
(государственный университет)
Факультет управления и прикладной математики
Кафедра «Интеллектуальные системы»

Москва, 2016 г.

Постановка задачи

Задача классификации:

$X \in R^n$ — коллекция текстовых документов,

$Y = \{1, \dots, C\}$ — множество классов.

Документы хранятся в виде «мешка слов» и описываются бинарными признаками:

$$b_w(x) = [f_w(x) \geq th],$$

где $f_w(x)$ — частота встречаемости n -граммы в документе,
 th — порог встречаемости n -граммы.

Найти зависимости $y = f(x)$ по точкам обучающей выборки

$$X^l = (x_i, y_i)_{i=1}^l.$$

Критерий качества: $AUC, MAUC$.

Задача выделения терминов

Задача выделения терминов (*Term Extraction*): по коллекции текстовых документов сформировать лексикон коллекции.

В работе исследуются n -граммы, построенные одним из алгоритмов *Term Extraction*:

- на первом этапе формируется избыточный словарь, затем n - граммы отбираются из слов предложений текста **на основе морфологических и синтаксических правил**;
- второй этап (**статистический**) — автоматическое выделения ключевых фраз без привлечения внешней информации. Методы: **TF-IDF, Termhood**.

Цели исследования

- **Цель данного исследования:** разработать способы измерения качества выделения терминов в задачах классификации текстов.
- **Проблемы исследования:**
 - Как качество выделения терминов влияет на качество классификации?
 - Как построить чувствительный критерий качества выделения терминов?
- **Решение:** строить как можно более точные модели классификации и, измеряя их качество, тем самым измерять качество мультиграммных словарей терминов.

Наивный байесовский классификатор

Оптимальный байесовский классификатор:

$$a(x) = \arg \max_{y \in Y} P(y)p(x|y),$$

где $P(y)$ — вероятности появления объектов каждого из классов, $p(x|y) = p(x; \theta_y)$ — функции правдоподобия классов.

NB основан на гипотезе независимости признаков.

Гипотеза

Если признаки x^1, \dots, x^n являются независимыми случайными величинами, то

$$p(x|y) = p(x^1, x^2, \dots, x^n|y) = p(x^1|y) \cdots p(x^n|y),$$

где $p(x^j|y) = p(x^j; \theta_y^j)$ — плотность распределения значений j -го признака для класса y .



Экспоненциальное семейство распределений

Распределение $p(x)$ из **экспоненциального семейства распределений**, если его плотность может быть представлена в виде:

$$p(x|\theta, \varphi) = \exp\left(\frac{x\theta - c(\theta)}{a(\varphi)} + h(x, \varphi)\right),$$

где $c(\theta)$, $h(x, \varphi)$, $a(\varphi)$ — функциональные параметры распределения,

θ и φ — числовые параметры,

θ — параметр *сдвига*,

φ — параметр *разброса*.

Обозначим среднее значение j признака в классе y как

$$\langle x_i^j \rangle_y = \frac{1}{|X_y|} \sum_{x_i \in X_y} x_i^j.$$

Наивный линейный байесовский классификатор

Согласно гипотезе независимости признаков **принцип максимума логарифма правдоподобия** принимает вид:

$$\sum_{j=1}^n \sum_{y \in Y} \sum_{x_i \in X_y} \ln p(x^j; \theta_y^j) \rightarrow \max_{\theta_y^j}.$$

Теорема К. В. Воронцова

Если одномерные плотности $p(x^j, \theta_j^y)$ принадлежат экспоненциальному семейству распределений и $\Theta = (\theta_j^y)$ является точкой максимума правдоподобия, то

$$\theta_y^j = [c']^{-1}(\langle x_i^j \rangle_y).$$

Параметры NB с отбором признаков

Найти:

- ① w_y^j — вес j признака в классе y ;
- ② $K = \{k_1, \dots, k_m\}$ — число информативных признаков алгоритма классификации.

Отбор признаков: метод *Top-K*.

Пусть $Y = \{+1, -1\}$. Веса признаков:

$$w_y^j = \begin{cases} \sqrt{\langle x_i^j \rangle_{+1}} - \sqrt{\langle x_i^j \rangle_{-1}} & , w_y^j > 0 \\ 0 & , \text{в противном случае} \end{cases} \quad (1)$$

Соответствует распределениям из экспоненциального семейства с $\varphi^j = \varphi = 1$, $a(\varphi) = 1$, $h(x, \varphi) = 0$, $\theta = \sqrt{\mu}$, $c(\theta) = \frac{\theta^3}{3}$.

Композиция классификаторов


Композиция позволяет точнее настраивать веса NB за счет учета влияния модальности n -грамм.

Мультиграммы получены на 1 этапе алгоритма.

Лучшее качество классификации среди композиций у откалиброванной композиции NB классификаторов.

Метод	NB	Композиция		
		NB+wt SVM	ANN	NB+IR+wt SVM
macro average AUC	0,749	0,865	0,876	0,887
micro average AUC	0,733	0,873	0,880	0,880

Алгоритм построения откалиброванной композиции



Тематическая модель классификации

Тематическая модель появления слов в документах:

$$p(w|d) = \sum_{t \in T} p(w|t)p(t|d) = \sum_{t \in T} \phi_{wt}\theta_{td}$$

Тематическая модель классификации документов:

$$p(c|d) = \sum_{t \in T} p(c|t)p(t|d) = \sum_{t \in T} \psi_{ct}\theta_{td}$$

где c — класс, w — слово, t — тема, d — документ коллекции.

Задача максимизации логарифма мультимодального регуляризованного правдоподобия:

$$\sum_{m,d,w} n_{dw} \ln \sum_t \phi_{wt}\theta_{td} + \tau \sum_{d,c} m_{dc} \ln \sum_t \psi_{ct}\theta_{td} + R(\Phi, \Theta, \Psi) \rightarrow \max_{\Phi, \Theta, \Psi}$$

где $w \in W^m$, W^m — словарь терминов модальности m , $m \in M$.

Аддитивная регуляризация

Аддитивная регуляризация тематической модели (ARTM):

$$R(\Phi, \Theta, \Psi) = \sum_i \tau_i R_i(\Phi, \Theta, \Psi)$$

- разреживание Θ :

$$R(\Theta) = -\tau \sum_{d \in D} \sum_{t \in T} \ln \theta_{td} \rightarrow \max$$

- сглаживание Φ :

$$R(\Phi) = \tau \sum_{t \in T} \sum_{w \in W} \ln \phi_{wt} \rightarrow \max$$

- декорреляция тем как столбцов Φ :

$$R(\Phi) = -\frac{\tau}{2} \sum_{t \in S} \sum_{s \in S \setminus t} \sum_{w \in W} \phi_{wt} \phi_{ws} \rightarrow \max$$

где S — предметные темы, $S \subset T$.

Выборка

Два типа коллекций:

- коллекции с целыми авторефератами;
- коллекции с фрагментами авторефератов.

Эксперименты с фрагментами авторефератов проводились как на всей выборке, так и на подвыборке.

Описание подвыборки:

X^l — обучающая выборка, $|X^l| = 30000$

X^k — контрольная выборка, $|X^k| = 5000$


$x = (x^1, \dots, x^n)$, $n \geq 1$.

Сравнение униграммной и n -граммной моделей


Эксперименты проводились на целых авторефератах.

Мультиграммы получены на 1 этапе алгоритма.

NB стратегия каждый-против-каждого




(a) Географические науки против геолого-минералогических.




(b) Культурология против философских наук.

Сравнение униграммной и n -граммной моделей

NB стратегия один-против-всех




(c) Класс ветеринарные науки.



(d) Класс культурология.

Сравнение униграммной и n -граммной моделей

NB иерархическая стратегия



Для более чувствительной оценки методов выделения терминов было решено классифицировать фрагменты авторефераторов.

SVM, ARTM и композиция NB

Лучшее качество классификации фрагментов авторефератов показала тематическая модель классификации, построенная с помощью подхода ARTM и проинициализированная признаками, отобранными откалиброванной композицией NB.

macro average AUC

Метод	NB	Композиция NB	SVM	ARTM	ARTM (иниц. комп. NB)
1 этап	0,7842	0,8865	0,9276	0,9415	0,9914
TF-IDF	0,7444	0,8382	0,8795	0,9360	0,9902
Termhood	0,8003	0,8941	0,9090	0,9496	0,9987

micro average AUC

Метод	NB	Композиция NB	SVM	ARTM	ARTM (иниц. комп. NB)
1 этап	0,6756	0,8477	0,9461	0,9554	0,9898
TF-IDF	0,6788	0,8412	0,9139	0,9479	0,9970
Termhood	0,6334	0,8597	0,9321	0,9488	0,9990




Рис.: Сравнение моделей классификации на подвыборке объектов.

Композиция NB

Оценка качества выделения терминов фрагментов с помощью композиции NB:

Метод	1 этап	TF-IDF	Termhood
macro average AUC	0,8792	0,8267	0,9018
micro average AUC	0,8526	0,8468	0,8773

Зависимость AUC от длины фрагмента



Результаты, выносимые на защиту

- Предложен критерий для оценивания и сравнения алгоритмов выделения терминов, основанный на качестве классификации композиции NB.
- Проведены вычислительные эксперименты по сравнению униграммной и мультиграммной моделей классификации.
- Выполнена программная реализация алгоритмов классификации: NB, композиция NB, тематическая модель классификации (с помощью библиотеки BigARTM).