

Классификация документов в векторном пространстве. Сравнение методов Роккио и метода k -ближайших соседей

Матяско А.А.; Хаустов В.А.

Кафедра информатики

Белорусский государственный университет информатики и радиоэлектроники

Минск, Республика Беларусь

e-mail: {alexander.matyasko, victor.khaustov}@gmail.com

Аннотация—классификации текстов является задачей информационного поиска, заключающаяся в отнесении документа к одной из нескольких категорий. В представленной работе описаны и проводится сравнение метода Роккио и метода k -ближайших соседей (kNN-классификация) для задачи классификации документов.

Ключевые слова: классификация документов, метод Роккио, метод knn, информационный поиск

I. ВВЕДЕНИЕ

Одним из основных способов обмена информации является текст. Для работы с большими объемами текстовой информации были разработаны алгоритмы для её анализа и классификации. Задача классификации возникает во многих приложениях (автоматическое определение веб-спама, создание тематических каталогов, фильтрации контента и др.)

В данной работе рассматривается метод Роккио и k -ближайших соседей задачи векторной классификации документов и проводится их сравнение.

II. ВЕКТОРНАЯ МОДЕЛЬ ДОКУМЕНТА

В векторной модели документ представляется в виде вектора, где каждому термину сопоставлен некоторый вес:

$$d_j = (w_{1j}, w_{2j}, \dots, w_{nj})$$

В основе использования модели векторного пространства лежит гипотеза о компактности (классы образуют компактно локализованные подмножества в пространстве объектов) [1].



Рис. 1. Классификация в векторном пространстве

На рисунке 1 представлен пример классификации на три класса в векторном пространстве. Документы с одинаковым классом представлены в виде одинаковых геометрических фигур. Звездочкой обозначен документ, подлежащий классификации.

Векторная классификация сводится к разработке алгоритма, вычисляющего "хорошие" границы, где

термин "хорошие" означает высокую точность классификации на данных, не использованных в ходе обучения. Для векторной классификации документов необходимо определить границы между классами, поскольку именно они определяют результат классификации.

III. МЕТОД РОККИО

Наиболее известным методом определения границ классов является метод Роккио, в котором для идентификации границ используются центроиды. Центриод класса c вычисляется как усредненный вектор, или центр масс членов класса:

$$\bar{\mu}(c) = \frac{1}{|D_c|} \sum_{d \in D_c} \bar{v}(d) \quad [2]$$

Здесь D_c — множество документов из пространства D , принадлежащих классу c : $D_c = \{d: \langle d, c \rangle \in D\}$, $\bar{v}(d)$ — нормализованный вектор документа d .

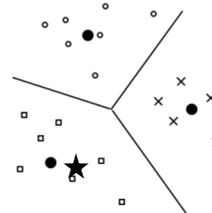


Рис. 2. Классификация методом Роккио

Граница между двумя классами в методе Роккио представляет собой множество точек, равноудаленных от двух центроидов. На рисунке 2 центроиды представлены в виде жирных точек. Правило классификации в алгоритме Роккио заключается в определении области, в которую попадает точка. Это эквивалентно поиску центроида $\bar{\mu}(c)$, к которому точка лежит ближе, чем к другим центроидам, и приписыванию этой точки к классу c . На рисунке 3 представлен псевдокод алгоритма Роккио.

```
TrainRocchio(C, D)
1 for each  $c_j \in C$ 
2 do  $D_j \leftarrow \{d: \langle d, c_j \rangle \in D\}$ 
3  $\bar{\mu}_j \leftarrow \frac{1}{|D_j|} \sum_{d \in D_j} \bar{v}(d)$ 
4 return  $\{\bar{\mu}_1, \bar{\mu}_2, \dots, \bar{\mu}_j\}$ 
ApplyRocchio(C, D)
1 return  $\arg \min_j |\bar{\mu}_j - \bar{v}(d)|$ 
```

Рис. 3. Классификация Роккио. Обучение и тестирование

IV. МЕТОД k -БЛИЖАЙШИХ СОСЕДЕЙ

Метод k -ближайших, или k NN-классификации, является одним из самых изученных и высокоэффективных алгоритмов, используемых при создании автоматических классификаторов.

На основании гипотезы о компактности классифицируемый объект относится к тому классу, к которому принадлежат k -ближайшие к нему объекты обучающей выборки. В варианте 1NN каждый документ относится к определенному классу в зависимости от информации о его ближайшем соседе. В варианте k NN документ относится к преобладающему классу ближайших соседей, где k — параметр метода.

Разделяющие границы в методе 1NN представляют собой смежные сегменты диаграммы Вороного. Диаграмма Вороного разделяет плоскость на $|D|$ выпуклых многоугольников, каждый из которых содержит соответствующий документ.

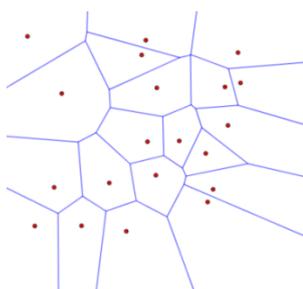


Рис. 4. Диаграмма Вороного и разделяющие границы в методе 1NN

Для произвольного параметра $k \in N$ в методе k NN область пространства, для которого множество k -ближайших соседей остается одинаковым, представляет собой выпуклый многоугольник, а пространство оказывается разделенным на выпуклые многоугольники, внутри каждого из которых множество k -ближайших соседей является инвариантным.

Метода 1NN не очень устойчив. Классификация каждого тестового документа зависит от класса, к которому относится отдельный обучающий документ, который может иметь неверную метку или вообще быть нетипичным. Метод k NN при $k > 1$ является более устойчивым [3]. Он приписывает документы к преобладающему классу по k ближайшим соседям, случайным образом разрывая связи между ними.

Параметр k в методе k NN часто выбирается на основании опыта и знаний о решаемой задаче

Табл. 1. Оценки временной сложности метода Роккио

Обучение	$\Theta(D L_{ave} + C V)$
Тестирование	$\Theta(L_a + C M_a) = \Theta(C M_a)$

Табл. 2. Оценки временной сложности классификатора k NN

Обучение	$\Theta(D L_{ave})$
Тестирование	$\Theta(L_a + D M_{ave}M_a) = \Theta(D M_{ave}M_a)$

классификации. Желательно, чтобы параметр был нечетным, что уменьшить вероятность “ничьей”.

```

Train-knn (C, D)
1  D' ← Preprocess (D)
2  k ← Select-k(C, D')
3  return D', k

Apply-kNN (C, D', k, d)
1  S ← ComputeNearestNeighbors(D', k, d)
2  for each cj ∈ C
3  do pj ← |Sk ∩ cj| / k
4  return argmax pj
    
```

Рис. 5. Метод k NN. Обучение и тестирование

V. СРАВНЕНИЕ

Классификация Роккио проста в реализации и эффективна по скорости работы, но неточна, если классы далеки от сфер с примерно одинаковыми радиусами.

В классификации по методу k NN не производится оценка ни одного параметра, как в методе Роккио (центроиды).

Временная сложность тестирования в методе k NN линейно зависит от размера обучающего множества и имеет большую временную сложность, чем в методе Роккио. В свою очередь, продолжительность тестирования не зависит от количества классов J . Следовательно, при большом количестве классов J метод k NN имеет потенциальные преимущества.

Метод k NN не требует явного обучения и допускает использование обучающего множества в процессе классификации без предварительной обработки. Если обучающее множество велико, то метод k NN лучше справляется с несферическими и другими сложными классами, чем метод Роккио [4].

В таблице 3 приведены значения эффективности методов Роккио и k NN для десяти самых больших категорий, а также усредненное значение по всем 90 категориям коллекции Reuters-21578.

- [1] Christopher D. Manning, Prabhakar Raghavan, Hinrich Schütze, “Introduction to Information Retrieval”, Cambridge University Press, 2008.
- [2] Thorsten Joachims, “A probabilistic analysis of the Rocchio algorithm with tfidf for text categorization”, Springer, 1997.
- [3] Hastie, Trevor, Robert Tibshirani, Jerome H. Friedman, “The Elements of Statistical Learning: Data Mining, Inference, and Prediction”, Springer, 2001.
- [4] Joachims Thorsten, “Learning to Classify Text Using Support Vector Machines”, Springer, 2002.

Табл. 3. Результаты сравнения методов

	Роккио	k NN
earn	96,1	97,8
acq	90,7	91,8
grain	79,5	82,6
crude	81,5	85,8
trade	77,4	77,9
interest	72,5	76,7
ship	83,1	79,8
wheat	79,4	72,9
corn	62,2	71,4
Усреднее	79,9	82,6