

КЛАССИФИКАЦИЯ ОТЗЫВОВ ПОЛЬЗОВАТЕЛЕЙ С ИСПОЛЬЗОВАНИЕМ ФРАГМЕНТНЫХ ПРАВИЛ

Васильев В. Г. (vvg_2000@mail.ru),
Худякова М. В. (mariya.kh@gmail.com),
Давыдов С. (davydov_sergey@hotmail.com)

ООО «ЛАН-ПРОЕКТ», Москва, Россия

В работе рассматривается подход к анализу отзывов пользователей, основанный на задании правил классификация и выделения значимых фрагментов на специальном языке. Проводится анализ эффективности автоматического построения и коррекции правил путем обучения на примерах. Приводятся результаты экспериментов в рамках соответствующей дорожки РОМИП 2011.

Ключевые слова: анализ отзывов пользователей, классификация, фрагментные правила

SENTIMENT CLASSIFICATION BY FRAGMENT RULES

Vasilyev V. G. (vvg_2000@mail.ru),
Khudyakova M. B. (mariya.kh@gmail.com),
Davydov S. (davydov_sergey@hotmail.com)

LAN-PROJECT, Moscow, Russia

In this paper approaches to sentiment classification based on using fragment rules are described. Rules are constructed manually by experts and automatically by using machine learning procedures. Training sets, evaluation metrics and experiments are used according to ROMIP 2011 sentiment analysis track.

Keywords: sentiment analysis, classification, fragment rules

1. Введение

В настоящее время в связи с активным развитием социальных сетей, форумов и блогов вопросы автоматизации анализа мнений пользователей сети по различным вопросам (отношение к товарам и услугам, событиям, высказываниям, сообщениям) вызывают большой интерес у многих организаций, что приводит к активизации научных исследований и экспериментов в данной области. Обычно задача анализа мнений пользователей ставится как задача классификации текстов на два или более класса, которые разделяют мнения на позитивные и негативные, а также их оттенки.

В работе [1] рассматриваются подходы к классификации отзывов на фильмы, основанные на сравнении числа положительных и отрицательных слов с учетом усиливающих терминов, а также использовании стандартного классификатора на основе машин опорных векторов. Как показывают проведенные авторами эксперименты при использовании первого подхода F-мера достигается порядка 60%–70%, а при использовании второго подхода порядка F-мера порядка 80%–85%. В работе [2] также как и в предыдущей работе рассматривается использование словарного подхода и обучения на примерах с использованием SVM. При этом реализована итерационная процедура пополнения словарей положительных и отрицательных терминов за счет классификации неразмеченных текстов. В целом эксперименты на массиве отзывов о различных товарах на китайском языке достигаются значения F-меры порядка 85%–90%. В работе [3] для классификации отзывов все предложения (высказывания) в тексте предварительно разбивают на личные и нейтральные и осуществляют построение трех классификаторов, которые обучаются на личных, нейтральных и всех предложениях с использованием метода SVM. Как показывают авторы такой подход позволяет несколько повысить качество по сравнению с базовым уровнем. В работе [4] приводится пример построения кросс языкового классификатора для анализа отзывов пользователей. Обучающая выборка представлена на английском языке, а обрабатываются переводы отзывов с китайского языка. Для обучения классификатора используется метод SVM и процедура использования неразмеченных текстов. В целом на отзывах о различных цифровых устройствах авторами были получены значения F-меры порядка 75%–80%. В работе [5] в отличие от предыдущих рассмотренных работ рассматривается задача классификации не отзывов о товарах, а мнений политиков о поправках к законам и результатов голосования. Помимо словарного и векторного подхода (метод SVM) для анализа отзывов в ряде работ строятся специальные вероятностные модели. Например, в [6] учитывается дерево синтаксического разбора предложений и зависимости между словами, а в работе [7] строится совместная тематико-оценочная вероятностная модель. Также в ряде работ авторы явно задают правила оценки текстов. В частности, в работе формулируются различные правила для определения области действия инверсных слов типа «не».

Таким образом, в работах по классификации отзывов применяются как стандартные методы классификации текстов, так и модифицированные методы,

в которых учитывается возможная инверсия значений оценочных слов, синтаксическая структура предложений, зависимости между словами [6]. Целью настоящей работы является исследование эффективности использования стандартных методов классификации текстов основанных на задании правил и обучении на примерах применительно к задаче классификации отзывов на русском языке, а также определение перспективных направлений совершенствования и развития данных алгоритмов. При этом в качестве основного рассматривается подход к классификации отзывов на основе правил, сформированных экспертами. Оценка эффективности рассматриваемых методов производится в рамках дорожки классификации отзывов пользователей на два класса.

2. Описание используемых подходов

2.1. Классификация на основе правил

Для задания правил в данной работе применяется подход, описанный в работе [8]. В данном случае оцениваемый текст D рассматривается как последовательность элементов (слов, цифр, знаков препинания), т. е. $D = (d_1, \dots, d_n)$, где $d_i \in T$ — отдельный элемент текста, $T = (t_1, \dots, t_m)$ — множество всех допустимых элементов, n — длина текста, m — число различных допустимых элементов текстов.

Множество $F = \{(p, q) \mid 1 \leq p \leq q \leq n\}$ будем называть множеством всех фрагментов текста длины n . Фрагментами текста будем называть отдельные элементы данного множества $f = (f_l, f_r) \in F$, которые задают левую f_l и правую f_r границы фрагмента (номер начального и конечного элемента текста). Результатом выполнения произвольного правила Q для текста D является множество $F_Q \subset F$, содержащее все фрагменты удовлетворяющие правилу Q . При этом, если $F_Q \neq \emptyset$, то будем говорить, что текст D удовлетворяет правилу Q .

Операции для задания правил можно разбить на следующие группы:

- элементарные — выделяют фрагменты, соответствующих отдельным словам;
- сложные — выделяют сложные многословных выражений;
- определяющие — задание общих понятий и множеств;
- управляющие — задают параметры классификации и обучения на примерах.

Элементарные операции — выделяют отдельные слова в тексте, предложения, строки, разделы документа. Например, правило $\$FirstUp$ — выделяет все слова в тексте с большой буквы, правило Липецкая — все слова, являющиеся словоформами слова «липецкая», правило «обл.*» — все слова начинающиеся на «обл.»; $\$Sentence$ — все предложения в документе, $\#section$ — раздел документа с определенным именем (например, заголовок).

Сложные операции — задания преобразования множеств фрагментов. Приведем примеры определения отдельных операций для построения сложного правила Q на основе правил Q_1, \dots, Q_k .

$Q = Q_1 \vee Q_2$ — бинарная операция ИЛИ, $F_Q \equiv R(F_{Q_1} \vee F_{Q_2})$, $F_{Q_1} \vee F_{Q_2} = \{f \in F \mid \exists f_1 \in F_{Q_1}, f \supseteq f_1 \text{ или } \exists f_2 \in F_{Q_2}, f \supseteq f_2\}$. Например, правило *искажение блеклый неуклюжий тьфу* выделяет фрагменты, равные соответствующие отдельным словам.

$Q = Q_1 \Delta_{n_1} Q_2$ — бинарная операция И с ограничением на расстояние между фрагментами, $F_Q \equiv R(F_{Q_1} \Delta_{n_1}^* F_{Q_2})$, $F_{Q_1} \Delta_{n_1}^* F_{Q_2} = \{f \in F \mid \exists f_1 \in F_{Q_1} \text{ и } \exists f_2 \in F_{Q_2}, \text{ т. что } f \supseteq f_1, f \supseteq f_2 \text{ и } d(f_1, f_2) \leq n_1\}$. Например, правило *смазанные &3 образы*, выделяет фрагменты, где расстояние между «смазанный» и «образ» не более 3 слов.

$Q = Q_1 \square_{n_1, n_2} Q_2$ — бинарная операция последовательности с ограничением на расстояние между фрагментами, $F_Q \equiv R(F_{Q_1} \square_{n_1, n_2}^* F_{Q_2})$, $F_{Q_1} \square_{n_1, n_2}^* F_{Q_2} = \{f \in F \mid \exists f_1 \in F_{Q_1} \text{ и } \exists f_2 \in F_{Q_2}, \text{ т. что } f_1 < f_2, d(f_1, f_2) > 0, f \supseteq f_1, f \supseteq f_2 \text{ и } n_1 \leq d(f_1, f_2) \leq n_2\}$. Например, *отказаться :3 (снимать производство)*, выделяет фрагменты, в которых после «отказаться» на расстоянии 3 слов находятся слова «снимать» или «производство».

$Q = \bowtie(Q_1, \dots, Q_k)$ — множественная операция последовательности соседних элементов (осуществляет отбор смежных фрагментов), $F_Q \equiv R(\bowtie^*(F_{Q_1}, \dots, F_{Q_k}))$, $\bowtie^*(F_{Q_1}, \dots, F_{Q_k}) = \{f \in F \mid \exists f_i \in F_{Q_i}, i=1, \dots, k, \text{ т. что } f_1 < f_{i+1}, d(f_i, f_{i+1})=1 \text{ для } i=1, \dots, k-1 \text{ и } f \supseteq f_i \text{ для } i=1, \dots, k\}$. Например, правило «начальник руководитель директор» («главное управление» управление организация отдел) (МВД МЧС МинФин) — выделяет словосочетания соответствующие руководителям различных ведомств.

$Q = Q_1 \wp Q_2$ — бинарная операция нахождения пересечения фрагментов, $F_Q \equiv \{f \in F \mid \exists f_1 \in F_{Q_1}, \exists f_2 \in F_{Q_2}, f \supseteq f_1 \text{ и } f \supseteq f_2\}$. Например, правило [великая \$FirstUp] — выделяет слова «великая», которые написаны с большой буквы.

$Q = Q_1 \triangleleft_{n_1, n_2}$ — унарная операция ограничения длины фрагмента, $F_Q \equiv \{f \in F_{Q_1} \mid n_1 \leq |f| \leq n_2\}$. Например, правило (Нижегородская & Владимирская) #IN #INTERVAL(2w/3w) — выделяет фрагменты, содержащие заданные слова длиной от 2 до 3 слов.

Для возможности построения правил включающих отрицания и условные операторы (наличие выражения проверяется, но оно не включается в итоговый фрагмент) используются специальные варианты бинарных правил, в которых один из операндов считается отрицательным или условным. В частности, символом \square_{n_1, n_2}^* обозначается операция нахождения последовательности, в которой второй операнд берется с отрицанием, символом $\square_{n_1, n_2}^{\leftarrow}$ — операция, в которой первый операнд берется с отрицанием, $\square_{n_1, n_2}^{\leftarrow}$ — операция, в которой первый операнд является условным. Определение $\square_{n_1, n_2}^{\leftarrow}$ имеет следующий вид $Q = Q_1 \square_{n_1, n_2}^{\leftarrow} Q_2$, где $F_Q \equiv \{f \in F_{Q_1} \mid \exists! f_2 \in F_{Q_2} \text{ т. что } f < f_2, 0 < n_1 \leq d(f, f_2) \leq n_2\}$.

Например, операция *без ^:3 отличн** — выделяет слова, начинающиеся на «отличн» перед которыми нет слова «без».

Определяющие операции — задают понятия в форме шаблонных подстановок (#define) и в форме сохраненных множеств фрагментов (#set). Для

обращения к подстановке и множеству фрагментов используются операторы @ и @@. Например, операция

#define Bad плохой глупый

задает понятие Bad, к которому можно обращаться из текста правила с помощью выражения @Bad.

Управляющие операции — задают параметры классификации и обучения. Например, операция #option train задает необходимость автоматического формирования правил путем обучения на примерах.

Для классификации отзывов был разработан набор понятий, из которых были сформированы правила для выделения положительных и отрицательных отзывов. Например, правило для определения отрицательных отзывов имеет следующий вид

@CheckBadBegin

@Bad & ^ (@CheckGoodBegin @CheckBadBegin @Good)

Оно работает следующим образом, сначала проверяются первые два предложения на содержание оценочных слов с использованием правила @CheckBadBegin, а затем проверяется наличие отрицательных слов при условии, что не найдены в начале текста положительные или отрицательные оценки.

Правило проверки на отрицательность начала текста проверяет, что в первых двух предложениях от начала документа перед отрицательным фрагментом нет положительного фрагмента и слова «не» или двойных кавычек. При этом понятие @@isbad является более строгим, а понятие @@badmark менее строгим.

Правило для проверки на отрицательность текста целиком @Bad является более сложным, но в целом похожим на @CheckBadBegin. Основу правил составляют понятия @@isgood, @@isbad, @@goodmark, @@badmark, которые выделяют множества исходных положительных и отрицательных фрагментов без учета модификаторов перед ними. Определение каждого такого понятия включает около сотни выражений.

В целом алгоритм оценки отзыва при использовании построенных правил имеет следующий вид.

Алгоритм 1. Классификация отзывов на основе правил

Шаг 1. Проверка начала текста, если решение однозначно, то завершить работу.

Шаг 2. Проверка текста в целом, если решение однозначно, то завершить работу.

Шаг 3. Вычисление веса положительных и отрицательных фрагментов;

Шаг 4. Отнесение текста к классу с наибольшим весом.

Построение правил классификации вручную является достаточно трудоемкой процедурой. По этой причине в используемом языке имеются операции, которые позволяют уточнить ранее построенное правило путем анализа результатов классификации обучающей подборки документов. В частности, правило для классификации отрицательных фрагментов было изменено следующим образом.

```
@CheckBadBegin
(@Bad @AutoSupplementQuery) & ^ (@CheckGoodBegin @CheckBadBegin)

#define AutoSupplementQuery $True
```

В приведенном правиле понятие *@AutoSupplementQuery* вычисляется автоматически таким образом, чтобы максимально повысить полноту правила, без снижения точности. Для формирования данного правила используется модифицированный вариант жадного алгоритма построения решающего списка [9], в котором в качестве множества положительных примеров используются неправильно классифицированные отрицательные тексты, а в качестве множества отрицательных примеров все положительные тексты.

Формирование обновленного правила происходит в соответствии со следующей схемой.

Алгоритм 2. Формирование обновленного правила

Шаг 1. Выполнить классификацию обучающего множества с помощью правила, в котором *@AutoSupplementQuery* не задан.

Шаг 2. Выполнить оценку качества классификации и построить *@AutoSupplementQuery* с использованием модифицированного варианта жадного алгоритма построения решающего списка.

Шаг 3. Выполнить дополнительную коррекцию построенного правила экспертом.

После построения модифицированного правила классификация отзывов происходит с использованием алгоритма 1.

2.2. Классификация с использованием обучаемых алгоритмов

В настоящее время разработано большое количество алгоритмов машинного обучения для решения задач классификации текстов. В данной работе был решено провести тестирование следующих стандартных алгоритмов [10]:

- алгоритм к-ближайших соседей;
- алгоритм построение деревьев решений C4.5;
- алгоритм на основе машин опорных векторов;

- байесовский классификатор на основе смеси многомерных нормальных распределений;
- байесовский классификатор на основе смеси распределений фон Мизеса-Фишера;
- центроидный классификатор Роччио.

Общая схема алгоритма обучения в данном случае является достаточно стандартной и имеет следующий вид.

Алгоритм 3. Обучение классификатора на примерах

1. Формирование векторного представления текстов в рамках модели «Bag Of Words».
2. Снижение размерности (селекция признаков по частоте) и вычисление весов признаков (TF_IDF).
3. Обучение и оценка классификатора на обучающей выборке с использованием 5-шаговой процедуры кросс-проверки.

3. Эксперименты

3.1. Описание тестовых массивов и показателей качества

В данной работе эксперименты по оценке качества проводились в рамках дорожки РОМИП 2011 классификации отзывов на два класса. Данная дорожка содержала три обучающих массива текстов:

- массив отзывов о фильмах — содержит 15 718 текстов, предоставленных онлайн-сервисом рекомендаций IMHONET, каждый отзыв оценен по 10 бальной шкале;
- массив отзывов о книгах — содержит 24 159 текстов, предоставленных онлайн-сервисом рекомендаций IMHONET, каждый отзыв оценен по 10 бальной шкале;
- массив отзывов о цифровых фотоаппаратах — содержит 10 370 текстов, предоставленных Yandex, каждый отзыв оценен по 5 бальной шкале.

Для тестирования использовался набор из 16 821 текстов, содержащих описание различных объектов интереса пользователей. Задачей дорожки было отнести каждый текст к классу положительных, либо к классу отрицательных отзывов.

Для оценки качества работы классификаторов в настоящей работе использовались следующие стандартные показатели качества: точность, полнота, F1-мера, аккуратность и среднее евклидово расстояние. Для первых трех показателей вычислялись значения, как для отдельных классов, так и макро-оценки.

3.2. Результаты экспериментов

Эксперименты проводились в два этапа. На первом этапе была выполнена самооценка качества классификации с использованием обучающего множества текстов, предоставленного организаторами дорожки. На втором этапе была выполнена обработка тестового множества текстов с использованием отдельных классификаторов и получены оценки качества от организаторов дорожки.

В следующей таблице приведены результаты самооценки качества, полученные с использованием классификаторов на основе правил. При этом классификатор на основе ручных правил обозначен Q1, а классификатор на основе обученных правил Q2.

Таблица 1. Результаты самооценки качества классификации с использованием правил

Классификатор	Объект	Точность положительные	Полнота положительные	Точность отрицательные	Полнота отрицательные
Q1	book	65%	66%	85%	43%
Q1	camera	71%	86%	83%	77%
Q1	film	60%	64%	71%	35%
Q2	book	71%	62%	84%	56%
Q2	camera	69%	88%	83%	81%
Q2	film	61%	67%	72%	37%

Как можно заметить из приведенной таблицы 1 использование процедуры обучения повышает полноту классификации на обучающем множестве, но при этом снижает немного точность.

Также были проведены эксперименты по оценке качества работу обучающихся алгоритмов. В следующей таблице, в качестве примера, приведены показатели качества для массива отзывов о книгах. В таблице 2 используются следующие обозначения алгоритмов: SVM — классификатор машин опорных векторов, GMM — байесовский классификатор на основе смеси многомерных нормальных распределений, ROC — классификатор Роччио, KNN — классификатор к-ближайших соседей, VMF — классификатор фон Мизеса-Фишера, TREE — классификатор на основе деревьев решений.

Таблица 2. Результаты оценки качества для массива отзывов о книгах

Классификатор	Объект	Точность положительные	Полнота положительные	Точность отрицательные	Полнота отрицательные
SVM	book	86%	99%	41%	44%
GMM	book	88%	73%	27%	42%
ROC	book	92%	18%	27%	8%
KNN	book	87%	78%	23%	30%
VMF	book	94%	47%	31%	57%
TREE	book	90%	70%	27%	30%

Как можно заметить из приведенной таблицы показатели качества для отрицательных текстов при использовании обучающих алгоритмов заметно хуже, чем при классификации на основе правил. При этом наиболее высокие показатели продемонстрировали алгоритмы: SVM, KNN, TREE. Алгоритм SVM и так достаточно часто используется в различных работах, по этой причине было решено отправить организаторам конкурса результаты обработки тестового массива с помощью алгоритмов KNN и TREE.

Организаторами дорожки для уменьшения субъективности оценок экспертов были рассмотрены 2 схемы оценок качества:

- схема И — учитываются только те отзывы, для которых совпадают оценки экспертов.
- схема ИЛИ — ответ алгоритма считается правильным, если он совпадает с ответом одного из экспертов.

Результаты экспериментов по каждой схеме приведены в следующих двух таблицах. В данные таблицы включена наилучшая оценка по дорожке и результаты оценки качества для 4 прогонов: Q1 — классификатор на основе правил, Q2 — модифицированный классификатор на основе правил, Q3 — классификатор на основе деревьев решений, Q4 — классификатор k-ближайших соседей.

Таблица 3. Результаты оценки качества в соответствии со схемой И

Метод	Объект	Макро-Точность	Макро-Полнота	Макро-F1
Q1	book	0.53	0.58	0.53
Q2	book	0.55	0.66	0.58
Q3	book	0.52	0.54	0.53
Q4	book	0.54	0.51	0.51
xxx-20	book	0.96	0.61	0.67
Baseline	book	0.46	0.5	0.48
Q1	camera	0.81	0.88	0.84

Метод	Объект	Макро-Точность	Макро-Полнота	Макро-F1
Q2	camera	0.79	0.87	0.83
Q3	camera	0.50	0.47	0.48
Q4	camera	0.93	0.54	0.53
xxx-24	camera	0.91	0.93	0.92
Baseline	camera	0.42	0.5	0.45
Q1	film	0.67	0.70	0.68
Q2	film	0.66	0.70	0.68
Q3	film	0.54	0.53	0.50
Q4	film	0.54	0.52	0.52
xxx-23	film	0.76	0.78	0.77
Baseline	film	0.42	0.5	0.45

Таблица 4. Результаты оценки качества в соответствии со схемой ИЛИ

Метод	Объект	Макро-Точность	Макро-Полнота	Макро-F1
q1	book	0.56	0.62	0.56
q2	book	0.57	0.69	0.61
q3	book	0.52	0.55	0.47
q4	book	0.54	0.51	0.51
xxx-20	book	0.73	0.74	0.73
Baseline	book	0.46	0.5	0.48
q1	camera	0.83	0.90	0.86
q2	camera	0.83	0.89	0.85
q3	camera	0.53	0.52	0.51
q4	camera	0.93	0.54	0.53
xxx-24	camera	0.92	0.94	0.93
Baseline	camera	0.43	0.5	0.48
q1	film	0.69	0.73	0.71
q2	film	0.68	0.73	0.70
q3	film	0.56	0.57	0.53
q4	film	0.54	0.53	0.53
xxx-23	film	0.78	0.80	0.79
Baseline	film	0.42	0.5	0.46

Анализ результатов, приведенных в таблицах 3 и 4, позволяет сделать следующие выводы. Методы классификации на основе правил показали более высокое качество работы. Значительно лучше обрабатывается массив с камерами, что связано с тем, что первоначальная настройка правил делалась

именно на нем. Обучаемые методы показали низкое качество работы возможно по следующим причинам: учитывались все признаки в текстах, не учитывался контекст употребления слов, методы на основе деревьев решений и классификатор ближайших соседей на обучающей выборке работали хуже метода SVM.

4. Выводы

Таким образом, в настоящей работе рассмотрены несколько подходов к классификации отзывов пользователей. Наиболее эффективным оказался подход, основанный на ручном построении правил экспертами. Использование традиционных методов обучения на примерах, а также расширения запросов с помощью отдельных терминов не приводит к высокому качеству классификации. Это связано, по-видимому, с тем, что в стандартных методах используется теоретико-множественная модель текстов, в которой не учитывается контекст употребления слов.

В качестве перспективных направлений дальнейших исследований можно сформулировать следующие: реализация специальных обучающих алгоритмов для формирования контекстных правил для заданных пользователем оцениваемых объектов, что позволит значительно снизить трудоемкость формирования правил экспертами; выполнение обучения классификаторов не на полных текстах, а на отдельных предложениях, содержащих ссылки на оцениваемый объект; использование при обучении на примерах только словарных признаков, отобранных экспертами; задание весов различным терминам при формировании правил экспертами и реализация специальных инструментальных средств для упрощения работы экспертов-лингвистов по формированию правил.

References

1. *Kennedy A., D. Inkpen* (2006) Sentiment classification of movie reviews using contextual valence shifters. *Computational Intelligence*, Vol.22, No 2, pp. 110–125.
2. *Qiu L., Zhang W., Hu C., Zhao K.* SELC: a self-supervised model for sentiment classification. *Proceedings of the 18th ACM conference on Information and knowledge management (CIKM '09)*, New York, USA, 2009, pp. 929–936.
3. *Li S.* et al. Employing Personal/Impersonal Views in Supervised and Semi-supervised Sentiment Classification. *Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics*, 2010, pp. 414–423.
4. *Wan X.* Co-Training for Cross-Lingual Sentiment Classification. *Proceedings of the 47th Annual Meeting of the ACL and the 4th IJCNLP of the AFNLP*, 2009, pp. 235–243.

5. *Thomas M., Pang B., Lee L.* Get out the vote: Determining support or opposition from congressional floor-debate transcripts. Proceedings of the 2006 Conference on Empirical Methods in Natural Language Processing, 2006, pp. 327–335.
6. *Nakagawa T., Inui K., S. Kurohashi,* Dependency Tree-based Sentiment Classification using CRFs with Hidden Variables. Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the ACL, 2010, pp. 786–794.
7. *He Y., Lin C., Alani H.* Automatically Extracting Polarity-Bearing Topics for Cross-Domain Sentiment Classification. Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics, 2011, pp. 123–131.
8. *Vasilyev V. G.* Fragment extraction and text classification by logical rules [Klasifikatsija i vydelenie fragmentov v tekstah na osnove logicheskikh pravil] Digital libraries: Advanced Methods and Technologies, Digital Collections RCDL'2011, Voronezh, 2011, pp. 133–139.
9. *Marchand M., Shawe-Taylor J.* Learning with the set covering machine. Proc. 18th International Conf. on Machine Learning, 2001, pp. 345–352.
10. *Vasilyev V. G.* (2008) Complex technology of automatic text classification [Kompleksnaja tehnologija avtomaticheskoi klassifikacii tekstov]. Komp'uternaia Lingvistika i Intellektual'nye Tehnologii: Trudy Mezhdunarodnoj Konferentsii "Dialog 2006" [Computational Linguistics and Intellectual Technologies: Proceedings of the International Conference "Dialog 2008"]. Bekasovo, 2008, pp. 83–90.