



Московский государственный университет имени М.В. Ломоносова
Факультет Вычислительной математики и кибернетики
Кафедра Математических методов прогнозирования

ДИПЛОМНАЯ РАБОТА

Сравнения моделей классификации основанных на множествах-прецедентах

Выполнил:

студент 517 группы
Антипов Алексей Алексеевич

Научный руководитель:

д.ф-м.н., профессор
Рязанов Владимир Васильевич

Москва, 2015

Оглавление

Оглавление.....	2
1 Введение	3
2 Алгоритмы классификации по множествам-прецедентам	4
2.1 Формализация задачи распознавания по множествам-прецедентам.....	4
2.2 Множества-прецеденты соответствующие логическим закономерностям	5
2.2.1 Первый способ описания логических закономерностей	7
2.2.2 Второй способ описания логических закономерностей	8
2.2.3 Третий способ описания логических закономерностей	9
2.3 Методы распознавания основанные на множествах-прецедентах.	9
3 Программные реализации алгоритмов распознавания по множествам-прецедентам.....	10
3.1 Реализация на MATLAB	10
3.2 Реализация на C++	11
3.1 Реализация модифицированного алгоритма k-ближайших соседей.....	12
4 Экспериментальные исследования на прикладных и модельных задачах.....	13
4.1 Сравнение моделей классификации основанных на множествах-прецедентах описанных первым способом и моделей классификации основанных на первоначальном представлении данных.....	13
4.2 Сравнение моделей классификации основанных на множествах-прецедентах описанных вторым способом и моделей классификации основанных на первоначальном представлении данных.....	16
4.3 Сравнение моделей классификации основанных на множествах-прецедентах описанных третьим способом и моделей классификации основанных на первоначальном представлении данных.....	19
4.4 Сравнение модифицированного и стандартного алгоритма k-ближайших соседей	22
4.5 Сравнение моделей классификации основанных на множествах-прецедентах описанных первым, вторым и третьим способами	23
4.6 Сравнение моделей классификации основанных на множествах-прецедентах на модельных данных.....	26
4.7 Анализ результатов экспериментов	28
5 Заключение	28
6 Список литературы	29

1 Введение

Двадцать первый век по праву называют веком информационных технологий. Рост компьютеризации и информатизации различных сфер общественной жизни влечет за собой взрывной рост объёмов и многообразия обрабатываемых данных, что создает необходимость развития научных областей и средств, отвечающих за анализ данных. Одной из основных таких областей является *машинное обучение*.

Машинное обучение (Machine Learning) — обширный подраздел искусственного интеллекта, изучающий методы построения алгоритмов, способных обучаться. Различают два типа обучения: *Обучение по прецедентам*, оно основано на выявлении общих закономерностей по частным эмпирическим данным, и *дедуктивное обучение*, которое предполагает формализацию знаний экспертов и их перенос в компьютер в виде базы знаний. Но дедуктивное обучение принято относить к области экспертных систем, поэтому термины машинное обучение и обучение по прецедентам можно считать синонимами.[1]

В данной работе рассматриваются задачи обучения по прецедентам. Эти задачи часто встречаются в самых разных областях человеческой деятельности.

Задача обучения по прецедентам состоит в следующем. Дано конечное множество прецедентов (объектов), по каждому из которых собраны (измерены) некоторые данные. Данные о прецеденте называют также его *описанием*. Совокупность всех имеющихся описаний прецедентов называется *обучающей выборкой*. Требуется по этим частным данным выявить общие зависимости, закономерности, взаимосвязи, присущие не только этой конкретной выборке, а всем прецедентам, в том числе тем, которые ещё не наблюдались.

Наиболее распространённым способом описания данных о выборке является признаковое описание отдельных объектов. Основная идея данной работы состоит в том, чтобы в качестве прецедентов рассматривать не отдельные объекты, а множества таких объектов. То есть группировать объекты определенным образом и описывать в качестве прецедентов уже не отдельный объект, а полученные группы объектов. Такой подход является более общим, так как в частном случае, если в качестве таких множеств взять множества, включающие в себя по одному объекту, мы вернемся к исходной задаче. Потенциально, новое описание может быть более информативным и удобным для конкретных задач, чем исходное.

В рамках данной работы в качестве множеств объектов рассматриваются множества, полученные на основе *логических закономерности классов*.

Логическая закономерность в задачах классификации — это легко интерпретируемое правило, выделяющее из обучающей выборки достаточно много объектов какого-то одного класса и практически не выделяющее объекты остальных классов.

В данной работе представлены несколько способов описания множеств-прецедентов, соответствующих логическим закономерностям. Реализованы программы (на языке *Matlab* и на языке *C++*), которые преобразуют исходные выборки и набор логических закономерностей (найденный с помощью системы интеллектуального анализа данных, распознавания и прогноза *Recognition 2.0*) в новое представление пригодное для дальнейшего использования в данной системе. Также проведен ряд экспериментов по сравнению новых и исходных описаний.

2 Алгоритмы классификации по множествам-прецедентам

2.1 Формализация задачи распознавания по множествам-прецедентам

Рассмотрим математическую постановку задачи распознавания по прецедентам.

Пусть X — множество описаний объектов, Y — множество допустимых ответов. Существует неизвестная целевая зависимость — отображение $y^*: X \rightarrow Y$, значения которой известны только на объектах конечной обучающей выборки $X_{train}^n = \{(x_1, y_1), \dots, (x_n, y_n)\}$. Требуется построить алгоритм $a: X \rightarrow Y$, который приближал бы неизвестную целевую зависимость, как на элементах выборки, так и на всём множестве X . Пусть $X_{test}^m = \{x_1, \dots, x_m\}$ тестовая выборка [1]. Тогда, чтобы решить задачу распознавания тестовой выборки, достаточно применить к ней построенный по обучающей выборке алгоритм a .

Теперь введем обозначения для задачи распознавания по множествам-прецедентам.

Пусть теперь \tilde{X} — новое множество описаний объектов, объектами которого являются подмножества X . Множество допустимых ответов — Y (остаётся неизменным). Аналогично, известна обучающая выборка $\tilde{X}_{train}^n = \{(\tilde{x}_1, y_1), \dots, (\tilde{x}_n, y_n)\}$. Требуется построить алгоритм $\tilde{a}: \tilde{X} \rightarrow Y$, приближающий неизвестную целевую зависимость, как на элементах выборки, так и на всём множестве \tilde{X} .

Чтобы перейти от задачи распознавания по прецедентам к задаче распознавания по множествам-прецедентам необходимо задать два отображения:

1. $x_{train}: X \times Y \rightarrow \tilde{X} \times Y$
2. $x_{test}: X \rightarrow \tilde{X}$

Тогда, чтобы решить задачу распознавания по прецедентам с помощью перехода к задаче распознавания по множествам-прецедентам, наложим на отображение x_{test} условие однозначности. Алгоритм решения задачи распознавания по прецедентам с помощью

перехода к задаче распознаванию по множествам-прецедентам будет иметь следующий вид:

Вход: $X_{train}^n = \{(x_1, y_1), \dots, (x_n, y_n)\}$ – обучающая выборка

$X_{test}^m = \{x_1, \dots, x_m\}$ распознаваемая выборка.

Параметры: отображения x_{train}, x_{test}

Выход: $Y^m = \{y_1, \dots, y_m\}$ вектор ответов для распознаваемой выборки

1. С помощью отображения $x_{train}: X \times Y \rightarrow \tilde{X} \times Y$, получаем из обучающей выборки $X_{train}^n = \{(x_1, y_1), \dots, (x_n, y_n)\}$, новую обучающую выборку $\tilde{X}_{train}^l = \{(\tilde{x}_1, y_1), \dots, (\tilde{x}_l, y_l)\}$
2. По $\tilde{X}_{train}^l = \{(\tilde{x}_1, y_1), \dots, (\tilde{x}_l, y_l)\}$ строим алгоритм $\tilde{a}: \tilde{X} \rightarrow Y$, приближающий неизвестную целевую зависимость, как на элементах выборки, так и на всём множестве \tilde{X}
3. Получаем распознаваемую выборку для пространства \tilde{X} : $\tilde{X}_{test}^m = x_{test}(X_{test}^m)$ и запоминаем соответствия между объектами X_{test}^m и полученными \tilde{X}_{test}^m
4. Получаем вектор ответов для распознаваемой выборки множеств-прецедентов $\tilde{Y}^m = \tilde{a}(\tilde{X}_{test}^m)$
5. Используя соответствие, полученное на *шаге 3* из вектора ответов \tilde{Y}^m , получаем вектор искомых ответов Y^m

Предположение состоит в том, что в пространстве \tilde{X} , при определенном выборе отображений x_{train}, x_{test} объекты из пространства X могут классифицироваться лучше, чем в самом пространстве X .

Прежде чем мы рассмотрим частный случай перехода от задачи распознавания по прецедентам к задаче распознавания по множествам-прецедентам, вспомним, что такое *логические закономерности классов* для задачи распознавания по прецедентам.

2.2 Множества-прецеденты соответствующие логическим закономерностям

Пусть $y \in Y$ — фиксированный класс. Объекты этого класса будем называть положительными; объекты остальных классов — отрицательными.

Под логической закономерностью класса $y \in Y$, понимается предикат вида:

$$\varphi(x) = (a_1 \leq x_1 \leq b_1) \cap (a_2 \leq x_2 \leq b_2) \cap \dots \cap (a_k \leq x_k \leq b_k) \in \{0,1\}$$

Где x_i — i -ая компонента вектора x , k — количество признаков.

Такой, что:

- 1) Существует хотя бы один объект обучающей выборки $(\bar{x}, \bar{y}) \in X_{train}^n$, для которого $\varphi(\bar{x}) = 1$ и $\bar{y} = y$
- 2) Для любого объекта обучающей выборки $(x', y') \in X_{train}^n$ другого класса $y' \neq y$, $\varphi(x') = 0$
- 3) $\varphi(x)$ доставляет экстремум для некоторого критерия качества предикатов $\Phi(\varphi)$

В качестве критерия качества предикатов, обычно, используется стандартный критерий качества логических закономерностей:

$$\Phi(\varphi) = \frac{\sum_{i=1}^n \varphi(x_i)}{\sum_{i=1}^n [y_i = y]}$$

В силу многоэкстремальности задачи оптимизации $\Phi(\varphi)$, логическими закономерностями класса считаются все предикаты $\varphi(x)$, доставляющие локальный экстремум критерию $\Phi(\varphi)$. [5]

Вообще говоря, поиск логических закономерностей задача – трудная задача, которая выходит за рамки данной работы. Но так как она непосредственно связана с дальнейшими исследованиями, опишем, в чем заключается идея алгоритма поиска логических закономерностей классов.

Алгоритм состоит в решении последовательности однотипных задач. Опишем подобную задачу для фиксированного класса $y \in Y$.

Пусть $(\bar{x}, \bar{y}) \in X_{train}^n$ случайно выбранный обучающий объект класса $\bar{y} = y$ (будем называть его “опорным”). Поиск оптимального предиката $\Phi(\varphi)$ (т.е. значений параметров $a_1, a_2, \dots, a_k, b_1, b_2, \dots, b_k$) для опорного объекта \bar{x} , удовлетворяющего условию $\varphi(\bar{x}) = 1$, осуществляется сначала на некоторой неравномерной сетке пространства \mathbb{R}^k . После нахождения оптимального предиката $\varphi(x)$ на заданной сетке, происходит поиск оптимального предиката $\varphi(x)$ на более мелкой сетке, в окрестности ранее найденного $\varphi(x)$, и т.д. Задача поиска множества логических закономерностей, связанных с заданным опорным объектом считается решенной, если при переходе к более мелкой сетке не удастся найти предикат $\varphi(x)$ с более высоким значением критерия качества $\Phi(\varphi)$. Задача поиска оптимального $\varphi(x)$ на каждой сетке состоит в поиске максимальной совместной подсистемы некоторой системы неравенств при линейных ограничениях относительно бинарных переменных и некоторого ее решения. Последняя задача сводится к решению аналогичной задачи относительно вещественных переменных. В конечном итоге задача поиска оптимального предиката $\varphi(x)$ для опорного объекта \bar{x} заканчивается вычислением множества локально оптимальных предикатов $\varphi(x)$ со свойством $\varphi(x) = 1$, причем конъюнкции являются несократимыми (из них нельзя удалить какой-либо сомножитель). [6]

Все вычисления повторяются для m случайно выбранных “опорных” объектов класса y , а все найденные логические закономерности объединяются в одно множество логических закономерностей для данного класса.

Говорят, что предикат $\varphi: X \rightarrow \{0,1\}$ покрывает объект x , если $\varphi(x) = 1$

Итак, любую логическую закономерность $\varphi(x)$ можно поставить в однозначное соответствие с подмножеством объектов, $M_\varphi \subset X$ которых она покрывает.

Теперь рассмотрим частный случай перехода от задачи распознавания по прецедентам к задаче распознавания по множествам-прецедентам.

В качестве множеств-прецедентов, будем рассматривать логические закономерности классов.

- Логические закономерности, которые будут являться множествами-прецедентами для обучения, можно найти из первоначальной обучающей выборки описанным выше алгоритмом.
- Для объектов тестовой выборки мы можем построить их, как конъюнкции фиксированного размера задаваемого параметрами $\varepsilon_1, \dots, \varepsilon_k$ с центром в тестовых объектах.

Теперь рассмотрим вопрос, как задать описание множеств-прецедентов \tilde{X} . Объектами теперь являются логические закономерности. В данной работе предложено 3 способа описания:

1. В форме бинарного вектора размерность, которого равна количеству объектов в обучающей выборке.
2. В форме многомерного параллелепипеда в первоначальном признаковом пространстве.
3. В виде центра массы логической закономерности

Распишем эти способы более подробно.

2.2.1 Первый способ описания логических закономерностей

Логическую закономерность $\varphi(x)$ можно представить в виде бинарного вектора следующего вида.

$$\varphi(x) = (\tilde{x}_\varphi^1, \tilde{x}_\varphi^2, \dots, \tilde{x}_\varphi^n),$$

где n - число объектов обучающей выборки

$$\tilde{x}_\varphi^i = \begin{cases} 1, & \varphi(x_i) = 1, \\ 0, & \text{иначе} \end{cases}, i = 1 \dots n$$

То есть, если объект обучающей выборки покрыт логической закономерностью, то в соответствующей координате стоит 1, в противном случае – 0.

Логические закономерности, соответствующие объектам обучающей выборки, можно найти методом, подробно описанным в [5], подробное описание которого выходит за рамки данной работы.

А каждому объекту тестовой выборки ставим в соответствие логическую закономерность (многомерные параллелепипеды) с центром в данном объекте тестовой выборки и расстоянием до границ, которое определяется при анализе логических закономерностей обучающей выборки (например, как среднее расстояние от центра до границ логических закономерностей в обучающей выборке). Хотелось отметить, что полученное отображение x_{test} является взаимно-однозначным. Далее аналогично проверяем, какие объекты обучающей выборки покрывает данная логическая закономерность, и формируем бинарный вектор.

2.2.2 Второй способ описания логических закономерностей

Пусть логическая закономерность $\varphi(x)$ представлена в виде конъюнкции пороговых правил

$$\varphi(x) = \bigcap_{i=1}^k [a_i \leq x_i \leq b_i],$$

где k - число признаков исходной задачи.

Для однородности представлений, если какой-то признак или граница не используется, заменим ее несущественным ограничением (например, левую границу можно заменить наименьшим значением данного признака на обучающей выборке, а правую границу – наибольшим значением данного признака на обучающей выборке).

Тогда данной логической закономерности однозначно соответствует описание в виде вектора размерности $2 * k$, первые k размерностей, которого описывает центр данной логической закономерности, то есть

$$\tilde{x}_{\varphi}^i = \frac{a_i + b_i}{2}, i = 1 \dots k$$

А остальные k размерностей описывают размер данной логической закономерности (расстояние от центра логической закономерности до ее границ)

$$\tilde{x}_{\varphi}^{i+k} = \frac{b_i - a_i}{2}, i = 1 \dots k$$

Аналогично первому способу, логические закономерности, соответствующие объектам обучающей выборки, можно найти методом, подробно описанным в [5], подробное описание которого выходит за рамки данной работы.

А каждому объекту тестовой выборки ставим в соответствие логические закономерности (многомерные параллелепипеды) с центром в данном объекте тестовой выборки и расстоянием до границ, которое определяется при анализе логических закономерностей обучающей выборки (например, как среднее расстояние от центра до границ логических закономерностей в обучающей выборке). Хотелось отметить, что полученное отображение x_{test} является взаимно-однозначным.

2.2.3 Третий способ описания логических закономерностей

Для обучающей выборки логическая закономерность описывается, как центр масс объектов, которые она покрывает.

$$\tilde{x}_\varphi = \frac{\sum_{i=1}^n \varphi(x_i) x_i}{\sum_{i=1}^n \varphi(x_i)},$$

Где x_1, \dots, x_n – объекты обучающей выборки, $\varphi(x_i) = 1$, если объект x_i покрывается логической закономерностью, $\varphi(x_i) = 0$ в противном случае.

Объекты тестовой выборки остаются без изменений (отображение x_{test} в этом случае тоже является взаимно-однозначным).

2.3 Методы распознавания основанные на множествах-прецедентах.

Объекты в новых представлениях имеют вид числовых векторов, поэтому с ними можно работать с помощью стандартных методов машинного обучения. Но при этом часть первоначальной информации (например, о расположении объектов внутри логических закономерностей) может теряться. Поэтому в данной работе мы рассмотрим еще и пример того, как можно совместно использовать начальное описание объектов и новое описание множествами-прецедентами. Но для этого необходимо модифицировать стандартные алгоритмы классификации. В данной работе приведен пример такой модификации для алгоритма k-ближайших соседей.

3 Программные реализации алгоритмов распознавания по множествам-прецедентам

Общий алгоритм

Вход: Имя файла с обучающей выборкой; имя файла с результатами поиска логических закономерностей системой Recognition 2.0; имя файла с тестовой выборкой

Выход: Файлы обучающей и тестовой выборки в первом, втором и третьем способах представления (которые описаны выше)

- Считывание файлов с обучающей и тестовой выборками, парсинг файла с логическими закономерностями
- Предобработка:
 - Замена пропусков в данных средним значением признака (в обучающей выборке среднее значение берется по классу, в тестовой – по всем объектам).
 - Нахождение минимальных и максимальных значений признаков для каждого класса (необходимо, чтобы ограничить найденные логические закономерности для неиспользуемых признаков).
- Формирование новых способов представления обучающих выборок
- Формирование новых тестовых выборок
 - Для первого и второго способа представления размер логических закономерностей для тестовых объектов выбирается, как средний размер логической закономерности для обучающих объектов
 - Для третьего способа представления тестовая выборка остается без изменений
- Запись в файл обучающей и тестовой выборки в первом, втором и третьем способах представления

3.1 Реализация на MATLAB

При создании программы были реализованы следующие функции:

```
cellfile = freadTab(nameInputFile)
% функция считывает файл с расширением .ТАВ

fwriteTab(nameOutputFile, cellfile, par)
% функция записывает внутреннее представление данных в файл.

cellLogRule = freadLogRule(nameFile)
```

```
% функция выделяет структурированную информацию
% из текстового файла с именем nameFile полученного
% после применение Recognition 2.0 -> Логические закономерности
```


```
creatNewTable( ... )
% основная функция, создающая новое представление обучающей
% и тестовой выборки описанными способами
```

```
commandFile.m
```

```
% скрипт, осуществляющий ввод параметров через управляющий файл
```

3.2 Реализация на C++

Также реализована программа на языке C++ с простым графическим интерфейсом для более удобного использования. Идейных отличий в реализации от языка MATLAB в программе нет.




3.1 Реализация модифицированного алгоритма k-ближайших соседей

Как и в предыдущих способах в качестве объектов обучающей выборки мы рассматриваем логические закономерности.

- Находим k-ближайшие к тестовому объекту логические закономерности $\varphi_1, \dots, \varphi_k$. Пусть y_1, \dots, y_k — классы найденных логических закономерностей
- Тестовый объект относим к классу, для которого сумма весов найденных k-ближайших логических закономерностей класса наибольшая.
$$a(x) = \operatorname{argmax}_{u \in Y} \sum_{i=1}^k w_i [y_i = u],$$
 где w_i — вес i-ой л.з.

Создается необходимость подсчета расстояния между объектом и логическими закономерностями. В данной реализации предлагаются три способа подсчета такого расстояния:

- 1) Расстоянием от тестового объекта до логической закономерности будем считать расстояние от тестового объекта до ближайшего к нему обучающего объекта покрываемого данной логической закономерностью
- 2) Расстоянием от тестового объекта до логической закономерности будем считать расстояние от тестового объекта до самого отдаленного от него обучающего объекта покрываемого данной логической закономерностью
- 3) Расстоянием от тестового объекта до логической закономерности будем считать среднее расстояние до всех обучающих объектов, покрываемых данной логической закономерностью




В таком подходе классификации можно учитывать веса логических закономерностей.

Пусть φ – логическая закономерность, x_1, \dots, x_n – объекты обучающей выборки. Тогда вес логической закономерности

$$w_\varphi = \frac{\sum_{i=1}^n \varphi(x_i)}{n}$$

Для данного алгоритма также реализована программа на языке С++ с простым графическим интерфейсом для более удобного использования.




4 Экспериментальные исследования на прикладных и модельных задачах

4.1 Сравнение моделей классификации основанных на множествах-прецедентах описанных первым способом и моделей классификации основанных на первоначальном представлении данных


Рассмотрим данные "Ion.tab". 2 класса. 34 признака. 169 объектов обучающей выборки: 57 объектов – 1 класса, и 112 объекта – 2 класса. 182 тестовых объекта: 69 объектов – 1 класса, 113 объектов – 2 класса.

На обучающей выборке программой Recognition 2.0 методом "Логические закономерности" было найдено 56 логических закономерностей, по 28 логических закономерностей для каждого класса.

Рассмотрим визуализацию начального представления данных. В качестве средства для визуализации выборки была использована программа Recognition 2.0.




“lon_l.tab”. Начальное представление. Обучающая выборка.




“lon_r.tab”. Начальное представление. Тестовая выборка.

Теперь рассмотрим визуализацию данных описанную *первым способом*.



“lon_l.tab”. *Первый способ*. Обучающая выборка.



“lon_r.tab”. Первый способ. Тестовая выборка.

Сравним качество этих двух представлений данных при классификации с помощью *линейного дискриминанта Фишера* (метод, разделяющий классы гиперплоскостью, построенной по статистическим свойствам выборки) и *линейной машины* (метод, строящий решающие правила в виде линейных функционалов для каждого класса).

При классификации тестовой выборки для **начального представления** данных с помощью линейного дискриминанта Фишера получаем следующие результаты:

Объектов, отнесенных в класс							
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2		
1	67 (36.8%)	53 (79.1%)	14 (20.9%)	53 (76.8%)	14 (12.4%)		
2	115 (63.2%)	99 (86.1%)	16 (13.9%)	16 (23.2%)	99 (87.6%)		
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)		
Итого							
	182 (100 %)	152 (83.5%)	30 (16.5%)	69 (37.9%)	113 (62.1%)		

При классификации тестовой выборки для представления данных **первым способом** с помощью линейного дискриминанта Фишера получаем следующие результаты:

Объектов, отнесенных в класс							
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2		
1	82 (45.1%)	66 (80.5%)	16 (19.5%)	66 (95.7%)	16 (14.2%)		
2	100 (54.9%)	97 (97.0%)	3 (3.0%)	3 (4.3%)	97 (85.8%)		
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)		
Итого							
	182 (100 %)	163 (89.6%)	19 (10.4%)	69 (37.9%)	113 (62.1%)		

При классификации тестовой выборки для **начального представления** данных с помощью линейной машины получаем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	61	(33.5%)	53	(86.9%)	8	(13.1%)	53	(76.8%)	8	(7.1%)
2	121	(66.5%)	105	(86.8%)	16	(13.2%)	16	(23.2%)	105	(92.9%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	182	(100 %)	158	(86.8%)	24	(13.2%)	69	(37.9%)	113	(62.1%)

При классификации тестовой выборки для представления данных **первым способом** с помощью линейной машины получаем следующие результаты:


Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	96	(52.7%)	66	(68.8%)	30	(31.3%)	66	(95.7%)	30	(26.5%)
2	86	(47.3%)	83	(96.5%)	3	(3.5%)	3	(4.3%)	83	(73.5%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	182	(100 %)	149	(81.9%)	33	(18.1%)	69	(37.9%)	113	(62.1%)

4.2 Сравнение моделей классификации основанных на множествах-прецедентах описанных вторым способом и моделей классификации основанных на первоначальном представлении данных


Рассмотрим данные "ech.tab". 2 класса. 8 признаков. 60 объектов обучающей выборки: 40 объектов – 1 класса, и 20 объектов – 2 класса. 71 тестовых объекта: 48 объектов – 1 класса, 23 объектов – 2 класса.

На обучающей выборке программой Recognition 2.0 методом "Логические закономерности" было найдено 40 логических закономерностей, 24 логических закономерностей для 1 класса, и 16 логических закономерностей для 2 класса.

Рассмотрим визуализацию начального представления данных. В качестве средства для визуализации выборки была использована программа Recognition 2.0.




“ech_l.tab”. Начальное представление. Обучающая выборка.




“ech_r.tab”. Начальное представление. Тестовая выборка.

Теперь рассмотрим визуализацию данных описанную *вторым способом*.



“ech_l.tab”. Второй способ. Обучающая выборка.



“ech_r.tab”. Второй способ. Тестовая выборка.

Сравним качество этих двух представлений данных при классификации с помощью *метода опорных векторов* (метод распознает образы с помощью разделяющей гиперплоскости и преобразования пространства признаков через потенциальную функцию) и *линейной машины* (метод, строящий решающие правила в виде линейных функционалов для каждого класса).

При классификации тестовой выборки для **начального представления** данных с помощью метода опорных векторов получаем следующие результаты:

Объектов, отнесенных в класс						
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2	
1	55 (77.5%)	42 (76.4%)	13 (23.6%)	42 (87.5%)	13 (56.5%)	
2	16 (22.5%)	10 (62.5%)	6 (37.5%)	6 (12.5%)	10 (43.5%)	
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)	
Итого						
	71 (100 %)	52 (73.2%)	19 (26.8%)	48 (67.6%)	23 (32.4%)	

При классификации тестовой выборки для **представления данных вторым способом** с помощью метода опорных векторов получаем следующие результаты:

Объектов, отнесенных в класс						
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2	
1	47 (66.2%)	39 (83.0%)	8 (17.0%)	39 (81.3%)	8 (34.8%)	
2	24 (33.8%)	15 (62.5%)	9 (37.5%)	9 (18.8%)	15 (65.2%)	
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)	
Итого						
	71 (100 %)	54 (76.1%)	17 (23.9%)	48 (67.6%)	23 (32.4%)	

При классификации тестовой выборки для **начального представления** данных с помощью *линейной машины* получаем следующие результаты:

Объектов, отнесенных в класс						
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2	
1	57 (80.3%)	42 (73.7%)	15 (26.3%)	42 (87.5%)	15 (65.2%)	
2	14 (19.7%)	8 (57.1%)	6 (42.9%)	6 (12.5%)	8 (34.8%)	
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)	
Итого						
	71 (100 %)	50 (70.4%)	21 (29.6%)	48 (67.6%)	23 (32.4%)	

При классификации тестовой выборки для представления данных **вторым способом** с помощью линейной машины получаем следующие результаты:


Объектов, отнесенных в класс						
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2	
1	44 (62.0%)	37 (84.1%)	7 (15.9%)	37 (77.1%)	7 (30.4%)	
2	27 (38.0%)	16 (59.3%)	11 (40.7%)	11 (22.9%)	16 (69.6%)	
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)	
Итого						
	71 (100 %)	53 (74.6%)	18 (25.4%)	48 (67.6%)	23 (32.4%)	

4.3 Сравнение моделей классификации основанных на множествах-прецедентах описанных третьим способом и моделей классификации основанных на первоначальном представлении данных


Рассмотрим данные "breast.tab". 2 класса. 9 признаков. 344 объектов обучающей выборки: 218 объектов – 1 класса, и 126 объектов – 2 класса. 355 тестовых объекта: 240 объектов – 1 класса, 115 объектов – 2 класса.

На обучающей выборке программой Recognition 2.0 методом "Логические закономерности" было найдено 54 логических закономерностей, 28 логических закономерностей для 1 класса, и 26 логических закономерностей для 2 класса.

Рассмотрим визуализацию начального представления данных. В качестве средства для визуализации выборки была использована программа Recognition 2.0.



“breast_l.tab”. Начальное представление. Обучающая выборка.




“breast_r.tab”. Начальное представление. Тестовая выборка.

Теперь рассмотрим визуализацию данных описанную *третьим способом*.



“breast_l.tab”. Третий способ. Обучающая выборка.



“breast_r.tab”. Третий способ. Тестовая выборка.

Сравним качество этих двух представлений данных при классификации с помощью *метода опорных векторов* (метод распознает образы с помощью разделяющей гиперплоскости и гиперплоскости и преобразования пространства признаков через потенциальную функцию) и *двумерных линейных разделителей* (метод использует голосование по двумерным решающим правилам).

При классификации тестовой выборки для **начального представления** данных с помощью метода опорных векторов получаем следующие результаты:

Объектов, отнесенных в класс							
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2		
1	233 (65.6%)	228 (97.9%)	5 (2.1%)	228 (95.0%)	5 (4.3%)		
2	122 (34.4%)	110 (90.2%)	12 (9.8%)	12 (5.0%)	110 (95.7%)		
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)		
Итого							
	355 (100 %)	338 (95.2%)	17 (4.8%)	240 (67.6%)	115 (32.4%)		

При классификации тестовой выборки для представления данных **третьим способом** с помощью метода опорных векторов получаем следующие результаты:

Объектов, отнесенных в класс							
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2		
1	239 (67.3%)	231 (96.7%)	8 (3.3%)	231 (96.3%)	8 (7.0%)		
2	116 (32.7%)	107 (92.2%)	9 (7.8%)	9 (3.8%)	107 (93.0%)		
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)		
Итого							
	355 (100 %)	338 (95.2%)	17 (4.8%)	240 (67.6%)	115 (32.4%)		

При классификации тестовой выборки для **начального представления** данных с помощью двумерных линейных разделителей получаем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	224	(63.1%)	223	(99.6%)	1	(0.4%)	223	(92.9%)	1	(0.9%)
2	131	(36.9%)	114	(87.0%)	17	(13.0%)	17	(7.1%)	114	(99.1%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	355	(100 %)	337	(94.9%)	18	(5.1%)	240	(67.6%)	115	(32.4%)

При классификации тестовой выборки для представления данных **третьим способом** с помощью двумерных линейных разделителей получаем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	239	(67.3%)	231	(96.7%)	8	(3.3%)	231	(96.3%)	8	(7.0%)
2	116	(32.7%)	107	(92.2%)	9	(7.8%)	9	(3.8%)	107	(93.0%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	355	(100 %)	338	(95.2%)	17	(4.8%)	240	(67.6%)	115	(32.4%)



4.4 Сравнение модифицированного и стандартного алгоритма k-ближайших соседей

Рассмотрим те же данные, что и в прошлом пункте “breast.tab” (см. пункт 4.3).

При классификации тестовой выборки для **начального представления** данных с помощью алгоритма k-ближайших соседей с автоопределением параметра k (числа ближайших соседей) имеем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	235	(66.2%)	229	(97.4%)	6	(2.6%)	229	(95.4%)	6	(5.2%)
2	120	(33.8%)	109	(90.8%)	11	(9.2%)	11	(4.6%)	109	(94.8%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	355	(100 %)	338	(95.2%)	17	(4.8%)	240	(67.6%)	115	(32.4%)

При классификации тестовой выборки с помощью **модифицированного алгоритма k-ближайших соседей** для трех способов подсчета расстояния между логической закономерностью и объектом (см. пункт 3.3) получаем следующие результаты:




4.5 Сравнение моделей классификации основанных на множествах-прецедентах описанных первым, вторым и третьим способами


Сравним наши способы описания данных на задаче кредитного скоринга ("credit.tab").

2 класса. 15 признаков. 342 объектов обучающей выборки: 152 объектов – 1 класса, и 190 объектов – 2 класса. 348 тестовых объектов: 155 объектов – 1 класса, 193 объектов – 2 класса.

Рассмотрим визуализацию начального представления данных. В качестве средства для визуализации выборки была использована программа Recognition 2.0.



“credit_l.tab”. Начальное представление. Обучающая выборка.



“credit_r.tab”. Начальное представление. Тестовая выборка.

При классификации тестовой выборки для представления данных **первым способом** данных с помощью алгоритма k-ближайших соседей с автоопределением параметра k (числа ближайших соседей) имеем следующие результаты:

Объектов, отнесенных в класс									
Класс	Объектов	Правильно	Ошибочно	Из класса 1	Из класса 2				
1	257 (73.9%)	144 (56.0%)	113 (44.0%)	144 (92.9%)	113 (58.5%)				
2	91 (26.1%)	80 (87.9%)	11 (12.1%)	11 (7.1%)	80 (41.5%)				
Отказы	0 (0.0%)			0 (0.0%)	0 (0.0%)				
Итого									
	348 (100 %)	224 (64.4%)	124 (35.6%)	155 (44.5%)	193 (55.5%)				


При классификации тестовой выборки для представления данных **вторым способом** данных с помощью алгоритма k-ближайших соседей с автоопределением параметра k (числа ближайших соседей) имеем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	76	(21.8%)	61	(80.3%)	15	(19.7%)	61	(39.4%)	15	(7.8%)
2	272	(78.2%)	178	(65.4%)	94	(34.6%)	94	(60.6%)	178	(92.2%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	348	(100 %)	239	(68.7%)	109	(31.3%)	155	(44.5%)	193	(55.5%)

При классификации тестовой выборки для представления данных **третьим способом** данных с помощью алгоритма k-ближайших соседей с автоопределением параметра k (числа ближайших соседей) имеем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	154	(44.3%)	112	(72.7%)	42	(27.3%)	112	(72.3%)	42	(21.8%)
2	194	(55.7%)	151	(77.8%)	43	(22.2%)	43	(27.7%)	151	(78.2%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
Итого										
	348	(100 %)	263	(75.6%)	85	(24.4%)	155	(44.5%)	193	(55.5%)

При классификации тестовой выборки с помощью **модифицированного алгоритма k-ближайших соседей** получаем следующие результаты:




4.6 Сравнение моделей классификации основанных на множествах-прецедентах на модельных данных

Сгенерируем обучающую и тестовую выборку следующим образом:

2 класса. 8 признаков. В обучающей и тестовой выборке по 10000 объектов – по 5000 объектов

каждого класса. $X \sim \mathcal{N}(x|\mu, \Sigma)$, для первого класса $\mu = (0, \dots, 0)$, $\Sigma = \begin{bmatrix} 2 & 0 & \dots & 0 \\ 0 & 2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & 2 \end{bmatrix}$; для второго класса

$$\mu = (1, \dots, 1), \Sigma = \begin{bmatrix} 2 & 0 & \dots & 0 \\ 0 & 2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & 2 \end{bmatrix}$$



Визуализация модельных данных

Первый способ представления для модельных данных не рассматривается из-за больших длин бинарных векторов (10000 признаков).

При классификации тестовой выборки **для начального представления** с помощью линейной машины имеем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	4774	(47.7%)	3862	(80.9%)	912	(19.1%)	3862	(77.2%)	912	(18.2%)
2	5226	(52.3%)	4088	(78.2%)	1138	(21.8%)	1138	(22.8%)	4088	(81.8%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
	10000	(100 %)	7950	(79.5%)	2050	(20.5%)	5000	(50.0%)	5000	(50.0%)


При классификации тестовой выборки **для второго представления** с помощью линейной машины имеем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	3633	(36.3%)	3299	(90.8%)	334	(9.2%)	3299	(66.0%)	334	(6.7%)
2	6367	(63.7%)	4666	(73.3%)	1701	(26.7%)	1701	(34.0%)	4666	(93.3%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
	10000	(100 %)	7965	(79.7%)	2035	(20.4%)	5000	(50.0%)	5000	(50.0%)

При классификации тестовой выборки **для третьего представления** с помощью линейной машины имеем следующие результаты:

Объектов, отнесенных в класс										
Класс	Объектов		Правильно		Ошибочно		Из класса 1		Из класса 2	
1	4571	(45.7%)	3768	(82.4%)	803	(17.6%)	3768	(75.4%)	803	(16.1%)
2	5429	(54.3%)	4197	(77.3%)	1232	(22.7%)	1232	(24.6%)	4197	(83.9%)
Отказы	0	(0.0%)					0	(0.0%)	0	(0.0%)
	10000	(100 %)	7965	(79.7%)	2035	(20.4%)	5000	(50.0%)	5000	(50.0%)

При классификации тестовой выборки с помощью **модифицированного алгоритма k-ближайших соседей** получаем следующие результаты:



4.7 Анализ результатов экспериментов

- Эксперименты показали, что все рассмотренные способы описания множеств-прецедентов соответствующих логическим закономерностям на некоторых прикладных задачах могут конкурировать с первоначальным описанием данных.
- *Первый, второй и третий* способы описания уменьшают объемы обучающей выборки (так как количество найденных логических закономерностей, как правило, меньше количества объектов обучающей выборки, по которым их ищут)
- Самым нестабильным способом описания показал себя *первый* способ. Это можно объяснить слишком длинным описанием объектов
- Наилучшие результаты при сравнении способов описания множеств-прецедентов показывают *второй и третий* способы
- Наихудшим способом подсчета расстояния между объектом и логической закономерностью является расстояние от этого объекта до самого отдаленного объекта покрытого логической закономерностью
- Первый способ подсчета расстояния между объектом и логической закономерностью (*расстояние до ближайшего объекта, покрытого логической закономерностью*) лучше себя показывает на задачах с сильно пересекающимися классами. А третий способ подсчета расстояния (*среднее расстояние до всех объектов, покрываемых логической закономерностью*) лучше себя показывает на задачах с плавными границами между классами
- Проблемой *первого, второго и третьего* описания множеств-прецедентов состоит в том, что получившиеся обучающие выборки для новых представлений хорошо разделяются, но это снижает точность классификации тестовых выборок на границе классов

5 Заключение

- Предложен подход распознавания по множествам-прецедентам.
- Предложены несколько способов решения задачи распознавания по прецедентам с помощью перехода к задаче распознавания по множествам-прецедентам.
- Созданы программные реализации данных способов
- Проведены эксперименты по сравнению моделей основанных на стандартном подходе распознавания и моделей основанных на множествах-прецедентах на модельных и реальных задачах машинного обучения.

6 Список литературы

- [1] www.MachineLearning.ru — профессиональный вики-ресурс, посвященный машинному обучению и интеллектуальному анализу данных
- [2] Журавлев Ю. И., Рязанов В. В., Сенько О. В. «Распознавание». Математические методы. Программная система. Практические применения. — М.: Фазис, 2006.
- [3] Воронцов К. В. «Математические методы обучения по прецедентам».
- [4] Загоруйко Н. Г. Прикладные методы анализа данных и знаний. — Новосибирск: ИМ СО РАН, 1999. — 270 с.
- [5] Рязанов В.В., Сенько О.В. О некоторых моделях голосования и методах их оптимизации // Распознавание, классификация, прогноз: Матем. методы и их применение. М.: Наука, 1992. Вып. 3. С. 106-145.
- [6] Ryazanov V.V. Recognition algorithms based on local optimality criteria// Pattern Recognition and Image Analys. 1994. V. 4. №2 . P. 98-109.
- [7] Рязанов В. В. «Логические закономерности в задачах распознавания» Журнал вычислительной математики и математической физики, М.: Наука. Т.48, 2008, N 2, стр. 329-344
- [8] Duda, R. O., Hart, P. E., and Stork, D. G. Pattern Classification // John Wiley and Sons, 2nd edition, 2000
- [9] Laim S.B., Ryazanov V.V. The search of precedent-based logical regularities for recognition and data analysis problems // Pattern Recognition and Image Analys. 1997. V. 7. № 3. P. 322-333. 14. Журавлёв Ю.И., Рязанов В.В. Об извлечении знаний из выборок прецедентов
- [10] Н. В. Ковшов, В. Л. Моисеев, В. В. Рязанов, «Алгоритмы поиска логических закономерностей в задачах распознавания», Ж. вычисл. матем. и матем. физ., 2008, том 48, номер 2, 329–344
- [11] Журавлев Ю.И., Петров И.Б., Рязанов В.В. «Дискретные методы диагностики и анализа медицинской информации» Медицина в зеркале информатики. Сб. РАН отв. ред. О.М. Белоцерковский, А.С. Холодов, Москва: Наука, 2008г., с. 113-123.
- [12] Дьяконов В. П. Справочник по применению системы PC MATLAB. — М.: «Физматлит», 1993. — С. 112.