

*На правах рукописи*



**Сарин Константин Сергеевич**

**МЕТОДОЛОГИЯ ПОСТРОЕНИЯ ИНТЕРПРЕТИРУЕМЫХ  
НЕЧЕТКИХ КЛАССИФИКАТОРОВ,  
ОСНОВАННЫХ НА ПРАВИЛАХ**

Специальность 2.3.8 – Информатика и информационные процессы

**АВТОРЕФЕРАТ**  
диссертации на соискание ученой степени  
доктора технических наук

Томск – 2025

Работа выполнена в федеральном государственном автономном образовательном учреждении высшего образования «Томский государственный университет систем управления и радиоэлектроники (ТУСУР)».

Научный консультант – **Ходашинский Илья Александрович**,  
доктор технических наук профессор

Официальные оппоненты: **Курейчик Владимир Викторович**,  
доктор технических наук, профессор, заведующий кафедрой систем автоматизированного проектирования им. Виктора Михайловича Курейчика ФГАОУ ВО «Южный федеральный университет», г. Таганрог

**Катасёв Алексей Сергеевич**,  
доктор технических наук, профессор, профессор кафедры систем информационной безопасности ФГБОУ ВО «Казанский национальный исследовательский технический университет им. А. Н. Туполева – КАИ»

**Сырымкин Владимир Иванович**,  
доктор технических наук, профессор, профессор кафедры управления качеством ФГАОУ ВО «Национальный исследовательский Томский государственный университет»

Ведущая организация – Федеральное государственное бюджетное образовательное учреждение высшего образования «Воронежский государственный университет»

Защита состоится «25» декабря 2025 г. в 15 часов 15 минут на заседании диссертационного совета 24.2.415.06, созданного на базе ТУСУРа, по адресу: 634050, г. Томск, пр. Ленина, 40, ауд. 201.

С диссертацией можно ознакомиться в библиотеке ТУСУРа (г. Томск, ул. Красноармейская, 146) и на сайте ТУСУРа:  
<https://postgraduate.tusur.ru/urls/trnb5vfe>

Автореферат разослан «    » \_\_\_\_\_ 2025 г.

Ученый секретарь  
диссертационного совета



Костюченко Евгений  
Юрьевич

## **ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ**

### **Актуальность темы исследования и степень ее разработанности**

Системы искусственного интеллекта (СИИ), основанные на методах машинного обучения, широко применяются во многих сферах жизнедеятельности человека, и в том числе таких критически важных как здравоохранение, энергетика и безопасность. Поскольку решения, принимаемые такими системами, являются решениями с высокими ставками и влияют на жизни людей, появляется необходимость понимания того, как они были получены. Отсутствие такой возможности может понизить уровень доверия человека к результатам решений и вызвать опасения по поводу причинения вреда. Это может замедлить общественное принятие и внедрение СИИ.

В Национальной стратегии развития искусственного интеллекта на период до 2030 года, утвержденной указом Президента Российской Федерации от 10.10.2019 № 490 (ред. от 15.02.2024), отмечается, что отсутствие понимания того, как искусственный интеллект достигает результатов, является одной из причин низкого уровня доверия к современным технологиям искусственного интеллекта и может стать препятствием для их развития. В национальном стандарте Российской Федерации ГОСТ Р 59276-2020 «Системы искусственного интеллекта. Способы обеспечения доверия» одним из факторов снижения качества СИИ и доверия к ним указывается недостаточная понятность и объяснимость. В качестве способа достижения доверия предлагается использовать интеллектуальные алгоритмы обработки данных, обеспечивающие принятие системой объяснимых решений.

В последние годы произошел рост количества систем принятия решений, основанных на нейронных сетях глубокого обучения. Эмпирический успех моделей глубокого обучения обусловлен сочетанием эффективных алгоритмов обучения и их огромного параметрического пространства, которое может включать сотни слоев и миллионы параметров. Это является причиной того, что такие СИИ рассматриваются как сложные модели «черного ящика», исключающие прозрачность или поиск понимания механизма, на основе которого работает модель. В Национальной стратегии развития искусственного интеллекта на период до 2030 года отмечается, что алгоритмы работы нейронных сетей крайне сложны для интерпретации и, следовательно, результаты их работы могут быть подвергнуты сомнению и отменены человеком.

Решение указанной выше проблемы предлагается осуществлять с помощью объяснимого искусственного интеллекта (ОИИ). СИИ обладает свойством объяснимости, если способна предоставлять доказательства или обоснование человеку в поддержку своего решения. Взаимодействие человека и СИИ играет ключевую роль в ОИИ. Полученные системой знания должны использоваться для предоставления объяснений; кроме того, пользователи должны иметь возможность оспаривать и задавать вопросы системам, чтобы понять обоснование решения в соответствии со своими конкретными потребностями. СИИ, обладающие способностью объяснить человеку результат своего решения, также называют интерпретируемыми системами.

Нечеткие системы имеют большой потенциал в разработке решений ОИИ. Благодаря наличию базы продукционных правил они способны выразить закономерности в данных в ориентированной на человека форме, используя термины естественного языка. Такая возможность позволяет предоставить понятные объяснения используемых системой знаний, а также детали, касающиеся процесса вывода при принятии решений. С помощью теории нечеткой логики, лежащей в основе таких систем, была установлена связь между числовыми решениями и правилами на естественном языке. Таким образом, численные операции, осуществляющие процедуру принятия решения в нечетких системах, интерпретируются логическими рассуждениями во вполне понятной человеку лингвистической форме. Это побудило использовать нечеткие методы для разработки ОИИ.

Решением проблемы построения нечетких систем занимались А.Н. Аверкин, И.З. Батыршин, М.В. Бобырь, А.В. Боженюк, В.В. Борисов, Л.А. Гладков, М.И. Дли, А.С. Катасёв, С.М. Ковалев, Ю.И. Кудинов, В.В. Курейчик, Т.М. Леденева, И.А. Мочалов, В.Г. Синюк, В.И. Сырякин, В.Л. Хацкевич, И.А. Ходашинский, А.В. Язенин, Н.Г. Ярушкина, P. Angelov, J.C. Bezdek, O. Cordon, D. Dubois, D. Filev, A. Gonzalez, S. Guillaume, F. Herrera, H. Ishibuchi, V. Kosko, F. Kruse, E.H. Mamdani, J.M. Mendel, S. Oh, W. Pedrycz, H. Prade, P.K. Simpson, M. Sugeno, T. Takagi, H. Tanaka, R.R. Yager, T. Yasukawa, L. Wang, L. Zadeh и др.

Нечеткие классификаторы являются нечеткими системами, осуществляющими процесс классификации или нахождения класса объекта по известным значениям его признаков. Продукционные правила таких систем связывают значения признаков объекта, представленных в лингвистической форме, с их классом и позволяют объяснить человеку результат своего решения. Анализ известных методов построения нечетких классификаторов выявил, что при высокой точности полученные модели имеют недостатки интерпретируемости, а это является критичным для систем ОИИ. Нечеткие классификаторы типа Min-Max содержат большое количество правил и формы функций принадлежности, которые затруднительно интерпретировать в лингвистические термины. Генетические нечеткие системы помимо большого числа правил имеют весовые коэффициенты правил, что вызывает трудности для объяснения полученного результата. Трехэтапный метод построения нечетких систем также генерирует функции принадлежности, вызывающие сложности при интерпретации в лингвистические термины. Нейро-нечеткие системы содержат в консеквентной части правил не метку класса, а функцию от значений признаков образца, затрудняющую объяснение результата.

На основании вышеизложенного можно сделать вывод о том, что разработка методов и алгоритмов построения интерпретируемых нечетких классификаторов для систем ОИИ, позволяющих объяснить человеку результат своего решения, является актуальной проблемой, требующей исследований для ее решения.

#### **Цель и задачи исследования**

Цель исследования заключается в повышении эффективности обнаружения закономерностей в данных с помощью разработки и применения методологии

построения интерпретируемых нечетких классификаторов, основанных на правилах.

Для достижения поставленной цели необходимо решить следующие основные задачи.

1. Провести аналитический обзор методов построения нечетких классификаторов.

2. Разработать методологию построения интерпретируемых нечетких классификаторов, основанных на правилах, которая определяет совокупность методов анализа данных и их взаимодействие.

3. Разработать и программно реализовать эффективные алгоритмы однокритериальной и многокритериальной оптимизации для поиска оптимума в смешанном и дискретном пространстве.

4. Разработать метод разделения данных на обучающую и валидационную выборки, способный минимизировать потери характеристических свойств данных при разделении и повысить точность моделей машинного обучения.

5. Разработать алгоритм оптимизации параметров на основе градиентного спуска для повышения точности нечетких классификаторов, построенных метаэвристическими алгоритмами.

6. Разработать методику построения нечетких классификаторов на основе предложенной методологии, способную учитывать критерии точности и интерпретируемости и использующую разработанные алгоритмы и методы.

7. Провести вычислительные эксперименты для оценки точности и интерпретируемости нечетких классификаторов, построенных с помощью предлагаемой методики, и сравнить с известными интерпретируемыми прогностическими моделями.

8. Применить результаты исследования для прогнозирования эффективности реабилитации пациентов после перенесенной коронавирусной инфекции COVID-19 и синтеза согласующих цепей.

**Объектом исследования** является процесс построения систем ОИИ на основе анализа данных.

**Предметом исследования** являются методы и алгоритмы построения интерпретируемых нечетких классификаторов, основанных на правилах.

#### **Методы исследования**

В диссертационной работе применялись методы оптимизации, интеллектуального анализа данных, теории нечетких множеств, линейной алгебры, теории алгоритмов, теории вероятностей и математической статистики.

**Достоверность результатов** обеспечивается следующими основными факторами:

1) строгостью применения математических методов;

2) использованием общепринятых тестов и общедоступных наборов данных для проведения численных экспериментов по оптимизации и построению нечетких систем;

3) проведением экспериментов на лицензионном программном обеспечении MATLAB, результаты которых не противоречат результатам, полученным другими исследователями.

## **Научная новизна полученных результатов**

В диссертации получены следующие новые научные результаты.

1. Предложена методология построения интерпретируемых нечетких классификаторов, основанных на правилах, определяющая совокупность методов анализа данных и их взаимодействие. Отличительной особенностью методологии является совместное применение методов разделения данных на обучающую и валидационную выборки, метаэвристических методов смешанной многокритериальной оптимизации для одновременной структурной и параметрической оптимизации классификаторов и стратегий выбора классификатора из сформированного Парето-множества. Методология позволяет разрабатывать интерпретируемые нечеткие классификаторы, сопоставимые по точности с существующими аналогами.

2. Разработан метаэвристический алгоритм многокритериальной оптимизации для поиска в смешанном дискретно-непрерывном пространстве. Отличительной особенностью алгоритма является совместное применение метаэвристики «кукушкин поиск» для формирования непрерывных элементов решения и генетического оператора скрещивания для формирования дискретных элементов решения. Алгоритм позволяет улучшить эффективность поиска в смешанном пространстве по сравнению с широко используемым генетическим алгоритмом с недоминируемой сортировкой NSGAII.

3. Разработан метаэвристический алгоритм однокритериальной оптимизации на основе распределения вероятностей значений переменных для поиска в дискретном пространстве. Особенностью алгоритма является построение распределения вероятностей с помощью трансформации целевых значений решений в их весовые коэффициенты. Алгоритм позволяет улучшить эффективность поиска в бинарном пространстве по сравнению с широко используемыми генетическим алгоритмом и алгоритмом роящихся частиц.

4. Для оптимизации параметров нечеткого классификатора адаптирован алгоритм градиентного спуска, отличительной особенностью которого является представление нечеткого классификатора в виде системы разделяющих функций и нормирование их значений в целевой функции оптимизации. Алгоритм позволяет улучшить точность классификаторов, построенных метаэвристическим алгоритмом.

5. Предложен новый метод разделения данных при построении прогностических моделей машинного обучения, основанный на применении бинарного метаэвристического алгоритма для формирования обучающей и валидационной выборок близких по характеристикам к исходным данным. Метод позволяет улучшить точность и интерпретируемость нечетких классификаторов, построенных метаэвристическим алгоритмом смешанной многокритериальной оптимизации.

6. Разработана методика построения нечетких классификаторов с соблюдением компромисса «точность – интерпретируемость», отличительной особенностью методики является применение новых методов и алгоритмов, а именно:

1) смешанной многокритериальной оптимизации с алгоритмом на основе совместного применения метаэвристики «кукушкин поиск» и генетического оператора скрещивания для одновременной структурной и параметрической оптимизации классификаторов по критериям точности и интерпретируемости;

2) метода разделения данных на обучающую и валидационную выборки дискретным алгоритмом оптимизации на основе распределения вероятностей с трансформацией целевых значений;

3) адаптированного алгоритма градиентного спуска для параметрической оптимизации классификаторов, настраивающей параметры функций принадлежности.

Методика позволяет при сопоставимой точности улучшить интерпретируемость классификаторов по сравнению с известными прогностическими моделями, такими как генетические нечеткие системы FARC-ND и деревья решений CART.

**Теоретическая значимость работы** заключается в развитии технологии построения нечетких систем интеллектуального анализа данных. Методика построения нечетких классификаторов является инструментом извлечения знаний из данных и интерпретации результатов, облегчающих понимание и объяснение процессов принятия решений, связанных с классификацией объектов. Алгоритмы смешанной многокритериальной оптимизации и дискретной оптимизации могут применяться для решения задач глобальной параметрической оптимизации и комбинаторной оптимизации. Метод разделения данных может быть использован для борьбы с переобучением и выбора подходящей по сложности структуры при построении прогностических моделей другого типа, например, нейронных сетей, деревьев решений, моделей на основе дискриминантного анализа и метода опорных векторов.

**Практическая значимость работы** подтверждается использованием полученных в ней результатов в разработке программных средств:

- алгоритм смешанной многокритериальной оптимизации использовался для разработки программных средств синтеза согласующих цепей с заданной формой амплитудно-частотной характеристики;

- алгоритм дискретной оптимизации на основе распределения вероятностей с трансформацией целевых значений внедрен в экспериментальную версию интеллектуальной САПР «50ohm Tech Circuit Studio»;

- методика построения нечетких классификаторов применялась в разработке программных средств для построения интерпретируемых моделей прогнозирования эффективности реабилитации пациентов после перенесенной коронавирусной инфекции COVID-19.

Разработанные методология, методы и алгоритмы использованы при выполнении следующих проектов.

1. РФФ, № 24-21-00168 «Методы и алгоритмы построения нечетких адаптивных классификаторов для решения задач кибербезопасности» 2024-2025 гг.

2. РФФ, № 22-21-00021 «Интерпретируемый нечеткий классификатор рукописных данных для диагностики нейродегенеративных заболеваний» 2022-2023 гг.

3. НИР «Создание информационной системы защищенного управления гетерогенными сетями и устройствами, образующими инфраструктуру «интернета вещей», выполненной в рамках государственного задания Министерства образования и науки Российской Федерации на 2017-2019 гг., проект № 2.3583.2017/4.6.

4. НИР «Теоретические основы человеко-машинных интерфейсов», выполненной в рамках государственного задания Министерства образования и науки Российской Федерации на 2017-2019 гг., проект № 8.9628.2017/8.9.

5. РФФИ, № 16-07-00034 «Методы и инструментальные средства построения самообучающихся систем, основанных на нечетких правилах» 2016–2018 гг.

#### **Положения, выносимые на защиту**

1. Методология построения позволила сформировать интерпретируемые нечеткие классификаторы, основанные на правилах и сопоставимые по точности с существующими аналогами.

Соответствует п. 13 специальности: *разработка и применение методов распознавания образов, кластерного анализа, нейро-сетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных.*

2. Алгоритм смешанной многокритериальной оптимизации позволил статистически значимо (на уровне  $\alpha=0,05$ ) улучшить результаты поиска по сравнению с широко используемым генетическим алгоритмом с недоминируемой сортировкой NSGA II на общепринятых тестах ZDT и DTLZ. Значение обратного расстояния поколений в среднем уменьшилось на 95,47%. Степень доминирования увеличилась в среднем на 70,92%.

Соответствует п. 1 специальности: *разработка компьютерных методов и моделей описания, оценки и оптимизации информационных процессов и ресурсов, а также средств анализа и выявления закономерностей на основе обмена информацией пользователями и возможностей используемого программно-аппаратного обеспечения.*

3. Алгоритм дискретной оптимизации позволил статистически значимо (на уровне  $\alpha=0,05$ ) улучшить эффективность поиска в бинарном пространстве по сравнению с широко используемыми генетическим алгоритмом и алгоритмом роящихся частиц на общепринятых унимодальных и мультимодальных эталонных тестовых функциях. В среднем отклонение от оптимального значения целевой функции уменьшилось в 4,3 раза по сравнению с генетическим алгоритмом и в 10,1 раза по сравнению с бинарным алгоритмом роящихся частиц.

Соответствует п. 1 специальности: *разработка компьютерных методов и моделей описания, оценки и оптимизации информационных процессов и ресурсов, а также средств анализа и выявления закономерностей на основе обмена информацией пользователями и возможностей используемого программно-аппаратного обеспечения.*

4. Адаптированный алгоритм градиентного спуска позволил статистически значимо (на уровне  $\alpha=0,05$ ) повысить точность нечетких классификаторов, построенных метаэвристическим алгоритмом смешанной многокритериальной оптимизации «кукушкин поиск» с генетическим оператором скрещивания на 38

общедоступных наборах данных. Максимальное увеличение точности составило 5,1%.

Соответствует п. 1 специальности: *разработка компьютерных методов и моделей описания, оценки и оптимизации информационных процессов и ресурсов, а также средств анализа и выявления закономерностей на основе обмена информацией пользователями и возможностей используемого программно-аппаратного обеспечения.*

5. Метод разделения данных при построении нечетких классификаторов многокритериальным метаэвристическим алгоритмом на 38 общедоступных наборах данных позволил статистически значимо (на уровне  $\alpha=0,05$ ) повысить точность классификации по сравнению с построением без разделения данных. Максимальное увеличение точности составило 6,5%.

Соответствует п. 7 специальности: *разработка методов обработки, группировки и аннотирования информации, в том числе, извлеченной из сети интернет, для систем поддержки принятия решений, интеллектуального поиска, анализа.*

6. Метод разделения данных при построении нечетких классификаторов многокритериальным метаэвристическим алгоритмом на 38 общедоступных наборах данных позволил статистически значимо (на уровне  $\alpha=0,05$ ) повысить интерпретируемость классификаторов путем уменьшения количества правил, количества признаков и общего количества нечетких терминов по сравнению с построением без разделения данных.

Соответствует п. 7 специальности: *разработка методов обработки, группировки и аннотирования информации, в том числе, извлеченной из сети интернет, для систем поддержки принятия решений, интеллектуального поиска, анализа.*

7. Методика построения нечетких классификаторов на 38 общедоступных наборах данных позволила при сопоставимой точности статистически значимо (на уровне  $\alpha=0,05$ ) повысить интерпретируемость классификаторов путем уменьшения количества правил в среднем на 39,2%, количества признаков в среднем на 8%, общего количества нечетких терминов в среднем на 49,8% по сравнению с нечеткими классификаторами FARC-HD и количества правил в среднем на 81,9%, количества условий в правиле в среднем на 54,5% по сравнению с классификаторами на основе деревьев решений CART.

Соответствует п. 13 специальности: *разработка и применение методов распознавания образов, кластерного анализа, нейро-сетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных.*

### **Внедрение результатов диссертационного исследования**

Результаты диссертационного исследования использованы в следующем.

1. В разработке программных средств для прогнозирования эффективности реабилитации пациентов после перенесенной коронавирусной инфекции COVID-19. Внедрены в Томском научно-исследовательском институте курортологии и физиотерапии (Томском НИИКиФ).

2. В разработке программных средств для синтеза согласующих цепей. Внедрены в научно-исследовательском институте микроэлектронных система (НИИ МЭС) и ООО «Микроэлектронные системы».

3. В разработке интеллектуальной САПР «50ohm Tech Circuit Studio», позволяющей автоматически синтезировать структуры и параметры СВЧ интегральных схем. Внедрены в ООО «50ом Тех.».

4. В учебном процессе кафедры компьютерных систем в управлении и проектировании (КСУП) Томского государственного университета систем управления и радиоэлектроники (ТУСУР).

#### **Апробация работы**

Результаты работы представлялись и обсуждались на следующих конференциях.

– Международная IEEE Сибирская конференция по управлению и связи (SIBCON 2017), г. Астана, 2017 г.

– XVI Национальная конференция по искусственному интеллекту с международным участием (КИИ 2018), г. Москва, 2018 г.

– III Международная научная конференция «Интеллектуальные информационные технологии в технике и на производстве» (ИТИ–III), г. Сочи, 2018 г.

– Международная IEEE Сибирская конференция по управлению и связи (SIBCON 2019), г. Томск, 2019 г.

– Международная научно-методическая конференция «Современное образование: интеграция образования, науки, бизнеса и власти», г. Томск, 2023 г., 2025 г.

– XXXVII Международная научная конференция «Математические методы в технике и технологиях», г. Казань, 2024 г.

– Международная научно-практическая конференция «Электронные средства и системы управления», г. Томск, 2017 г., 2023 г., 2024 г.

– XXX Байкальская Всероссийская конференция с международным участием «Информационные и математические технологии в науке и управлении», г. Иркутск, 2025 г.

#### **Публикации**

По результатам исследования опубликовано 59 печатных работ, из которых в рекомендованных ВАК РФ периодических изданиях – 31. Двадцать работ индексируются в базах научных публикаций SCOPUS и WoS. Получены 8 свидетельств о государственной регистрации программ для ЭВМ.

#### **Личный вклад автора**

Автором проводилась постановка цели и задач научного исследования. Все результаты работы, составляющие научную новизну и сформулированные в положениях, выносимых на защиту, получены автором лично. Автором лично разработаны методология построения интерпретируемых нечетких классификаторов, алгоритм смешанной многокритериальной оптимизации, дискретный алгоритм оптимизации, метод разделения данных, адаптированный алгоритм градиентного спуска для настройки параметров нечетких классификаторов, методика построения интерпретируемых нечетких

классификаторов, а также программные средства, реализующие разработанные алгоритмы, метод разделения, методику построения. Кроме этого, автором разработаны программные средства, осуществляющие синтез цепей согласования и прогнозирования эффективности реабилитации. Также автором проведены вычислительные эксперименты для оценки эффективности разработанных алгоритмов оптимизации, метода разделения данных, адаптированного алгоритма градиентного спуска и методики построения интерпретируемых нечетких классификаторов. Вычислительный эксперимент для оценивания работы алгоритма смешанной многокритериальной оптимизации при синтезе согласующих цепей выполнен совместно с *Михаилом Владимировичем Черкашиным*. Формирование первичных данных для прогнозирования эффективности реабилитации пациентов после перенесенной коронавирусной инфекции COVID-19 выполнено совместно с сотрудниками Томского НИИКиФ. Результаты по отдельным направлениям получены совместно с соавторами научных публикаций.

### **Благодарности**

Автор выражает глубокую благодарность научному консультанту, профессору кафедры КСУП ТУСУРа, д-ру техн. наук проф. *Илье Александровичу Ходашинскому* за помощь и поддержку в выполнении настоящей работы. Автор выражает благодарность коллегам доценту кафедры КСУП, канд. техн. наук *Михаилу Олеговичу Светлакову*, доценту кафедры КСУП, канд. техн. наук *Марине Борисовне Бардамовой* и сотрудникам лаборатории интеллектуальных систем за обсуждение исследования, ряд ценных советов и замечаний.

### **Структура и объем диссертации**

Диссертация содержит введение, 4 раздела, заключение, список литературы из 289 наименований и приложений. Объем работы с приложениями составляет 260 с., в том числе 72 рисунка и 40 таблиц.

## **ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ**

**Во введении** обоснована актуальность темы исследования и степень ее разработанности, сформулированы цель и задачи работы, показана научная новизна, теоретическая и практическая значимость результатов. Изложены основные положения, выносимые на защиту, и сведения об апробации работы.

**В первом разделе** содержится аналитический обзор проблемы построения нечетких классификаторов с помощью методов анализа данных. Рассмотрены известные методы построения нечетких классификаторов, приведены основные преимущества и недостатки. Нечеткие классификаторы типа Min-Max используют инкрементную парадигму обучения, что позволяет адаптировать классификатор к вновь пришедшим данным без повторного обучения. Интерпретируемость классификаторов затруднительна, поскольку большое количество правил, которое доходит до тысяч, приводит к невозможности интерпретировать нечеткие множества в лингвистические термины. Кроме этого, в данных классификаторах отсутствует механизм отбора признаков. В генетических нечетких системах формируются нечеткие множества, близкие к равномерному разделению, что дает возможность их интерпретации в лингвистические термины. Большое количество

правил и их весовые коэффициенты усложняют интерпретируемость. В трехэтапном методе построения формируются классификаторы с небольшим количеством правил и используется отбор признаков. В то же время форма функций принадлежности может сильно отличаться от формы равномерного покрытия, что затрудняет интерпретацию функций в лингвистические термины и представление правил на естественном языке.

Представлена в формализованном виде проблема построения интерпретируемых нечетких классификаторов.

*Постановка проблемы.* В работе применяется нечеткий классификатор, в посылках продукционных правил которого содержатся значения признаков объекта, выраженные в лингвистической форме, а в заключение метка класса. Правила являются понятными для человека и выражают связь между признаками и классом, что является необходимым для объяснения результата прогноза:

$$\text{Правило } R_j: \text{ЕСЛИ } x_1 = A_{1j} \text{ И } \dots \text{ И } x_n = A_{nj} \text{ ТО класс} = c_j,$$

где  $j = 1, \dots, r$ ;  $r$  – количество правил;  $x_1, \dots, x_n$  – входные переменные;  $A_{ij}$  – нечеткий термин, характеризующий  $i$ -ю переменную в  $j$ -ом правиле;  $c_j \in \{\omega_1, \omega_2, \dots, \omega_M\}$  – метка класса в заключении  $j$ -го правила, указывающая на один из классов  $\omega_1, \dots, \omega_M$ .

Если построена база правил, то класс образца  $\mathbf{x} = (x_1, x_2, \dots, x_n)$  определяется классом разделяющей функции, имеющей максимальное значение:

$$\mathbf{x} \in \omega_j, \quad j = \arg \max_{k=1, \dots, M} (g_k(\mathbf{x})),$$

где  $g_k(\mathbf{x})$  – разделяющая функция  $k$ -го класса. В настоящем исследовании при нахождении ее значения применяются два вида агрегации правил. В первом случае агрегация основана на функции максимума. Значения разделяющих функций определяется следующим образом:

$$g_k(\mathbf{x}) = \max_{\substack{j, \\ c_j = \omega_k}} \left( \prod_{i=1}^n \mu_{ij}(x_i) \right),$$

где  $k = 1, \dots, M$ ;  $\mu_{ij}$  – функция принадлежности нечеткого множества термина  $A_{ij}$ .

Во втором случае агрегация правил определяется функцией суммы. Значения разделяющих функций рассчитывается согласно следующему выражению:

$$g_k(\mathbf{x}) = \sum_{\substack{j, \\ c_j = \omega_k}} \prod_{i=1}^n \mu_{ij}(x_i).$$

Формализация нечетких терминов осуществляется с помощью функций принадлежности, т.е. с каждым термином  $A_{ij}$  ассоциируется функция принадлежности  $\mu_{ij}(x_i)$ , определенная на множестве значений  $x_i$ . В работе использовались функции принадлежности гауссова типа, содержащие два параметра – среднее значение  $s$  и среднеквадратичное отклонение  $\sigma$ :

$$\mu(x) = e^{-\frac{(x-s)^2}{2\sigma^2}}.$$

Для построения классификаторов предоставлена размеченная выборка образцов данных, называемая исходными данными или таблицей наблюдений и состоящая из значений признаков образцов и их метки класса:

$$Data = \{(\mathbf{x}_p, l_p) \mid p = 1, 2, \dots, m\}, \quad (1)$$

где  $m$  – количество образцов исходных данных;  $\mathbf{x}_p = (x_{1p}, x_{2p}, \dots, x_{np})$  – вектор входных данных (признаков)  $p$ -го образца в  $n$ -мерном пространстве;  $x_{ip}$  – значение  $i$ -й переменной (признака)  $p$ -го образца;  $l_p$  – метка класса  $p$ -го образца;  $l_p \in \{\omega_1, \omega_2, \dots, \omega_M\}$ .

Целью построения нечетких классификаторов является достижение высокой точности и интерпретируемости. Таким образом, проблема построения сводится к проблеме многокритериальной оптимизации, которую можно представить следующим образом:

$$\begin{cases} \max_{\mathbf{C}} (Fun_1^1(\mathbf{C}), Fun_2^1(\mathbf{C}), \dots, Fun_1^2(\mathbf{C}), Fun_2^2(\mathbf{C}), \dots) \\ \mathbf{C} \in FC \end{cases},$$

где  $Fun_1^1(\mathbf{C}), Fun_2^1(\mathbf{C}), \dots$  – показатели точности классификатора  $\mathbf{C}$ ;  $Fun_1^2(\mathbf{C}), Fun_2^2(\mathbf{C}), \dots$  – показатели интерпретируемости классификатора  $\mathbf{C}$ ;  $FC$  – возможное множество классификаторов. Формула приведена в предположении, что большее значение показателей является лучшим.

Оценка эффективности классификаторов проводится по критериям точности и интерпретируемости. Для оценки точности применяется процент правильно классифицированных образцов выборки данных, не используемой для построения классификатора:

$$acc = \frac{n_{true}}{n_{all}} \cdot 100\%,$$

где  $n_{true}$  – число правильно классифицированных образцов тестовых данных;  $n_{all}$  – число образцов тестовых данных. Большее значение соответствует лучшей точности. Для оценки интерпретируемости нечетких классификаторов используется несколько показателей: количество правил  $\#R$ , количество признаков (входных переменных)  $\#F$ , общее количество нечетких терминов в базе правил  $\#T$ , среднее количество нечетких терминов в антецедентной части (посылке) правила  $\#D$ . Меньшее значение показателей соответствует лучшей интерпретируемости.

**Во втором разделе** представлены новые научные результаты, направленные на решение проблемы построения интерпретируемых моделей машинного обучения, позволяющих объяснить человеку результаты своего прогноза. Такими моделями выступают нечеткие классификаторы. Предложена методология, определяющая систему методов анализа данных и их взаимодействие для построения нечетких интерпретируемых классификаторов. Разработан алгоритм

смешанной многокритериальной оптимизации для построения нечетких классификаторов с соблюдением компромисса «точность-интерпретируемость». Разработан метод разделения данных на обучающую и валидационную выборки для сохранения их близости к исходной выборке и минимизации потерь информации при разделении. Разработан алгоритм дискретной оптимизации, применяемый в реализации метода разделения данных. Адаптирован алгоритм градиентного спуска, позволяющий настраивать параметры функций принадлежности нечеткого классификатора. В итоге предложена методика построения нечетких классификаторов, основанная на методологии построения и использующая разработанные алгоритмы и метод разделения.

*Методология построения нечетких классификаторов* определяют систему методов анализа данных и их взаимодействие при построении интерпретируемых классификаторов. Методология учитывает выявленные недостатки в ходе аналитического обзора и основана на следующих концептуальных положениях.

1. Построение классификаторов осуществляется многокритериальными методами оптимизации для соблюдения компромисса «точность–интерпретируемость».

2. При построении классификаторов применяется смешанная оптимизация, чтобы одновременно осуществить построение структуры и настройку параметров.

3. Разделение исходных данных на обучающую и валидационную выборки осуществляется с минимизацией потерь характеристических свойств.

4. Для дообучения классификаторов с целью повышения их точности применяются методы оптимизации, основанные на производных.

5. Форма и положение функций принадлежности нечетких множеств должны позволить интерпретировать их в лингвистические термины.

На рисунке 1 представлена диаграмма IDEF0 методологии, указаны процессы, в которых применяются методы, и их взаимодействие. Сначала исходные данные подвергаются преобразованию с помощью методов предобработки данных, устраняя дефекты, влияющие на качество анализа. Преобразование осуществляется программными средствами. Затем данные подвергаются разделению с целью получения обучающей и валидационной выборок. Это проводится методами разделения и осуществляется программными средствами. На основе метаэвристических методов смешанной многокритериальной оптимизации программные средства осуществляют построение множества недоминируемых по критериям точности и интерпретируемости нечетких классификаторов, используя обучающие данные. Предварительно эксперт должен определить лингвистические термины и их количество для каждой переменной. Далее из полученного множества выбирается наиболее эффективный классификатор. Выбор осуществляет эксперт или программные средства на основе стратегий выбора модели на фронте Парето с использованием валидационной выборки. Выбранная модель дообучается с помощью методов, основанных на производных. Данный процесс выполняют программные средства.

*Алгоритм смешанной многокритериальной оптимизации «кукушкин поиск»* с генетическим оператором скрещивания MICS (Mixed-Integer Cuckoo Search)

осуществляет поиск оптимума в смешанном пространстве, в котором присутствуют переменные дискретного и непрерывного типа. Формально данная проблема поиска может быть представлена следующим образом:

$$\begin{cases} \min_{\mathbf{x}} (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})) \\ \mathbf{x} = (x_1^d, x_2^d, \dots, x_k^d, x_1^c, x_2^c, \dots, x_l^c) \end{cases},$$

где  $f_i(\mathbf{x})$  –  $i$ -я целевая функция ( $i = 1, \dots, m$ );  $\mathbf{x}$  – вектор поиска;  $x_1^d, \dots, x_k^d$  – дискретные компоненты вектора поиска;  $x_1^c, \dots, x_l^c$  – непрерывные компоненты вектора поиска.

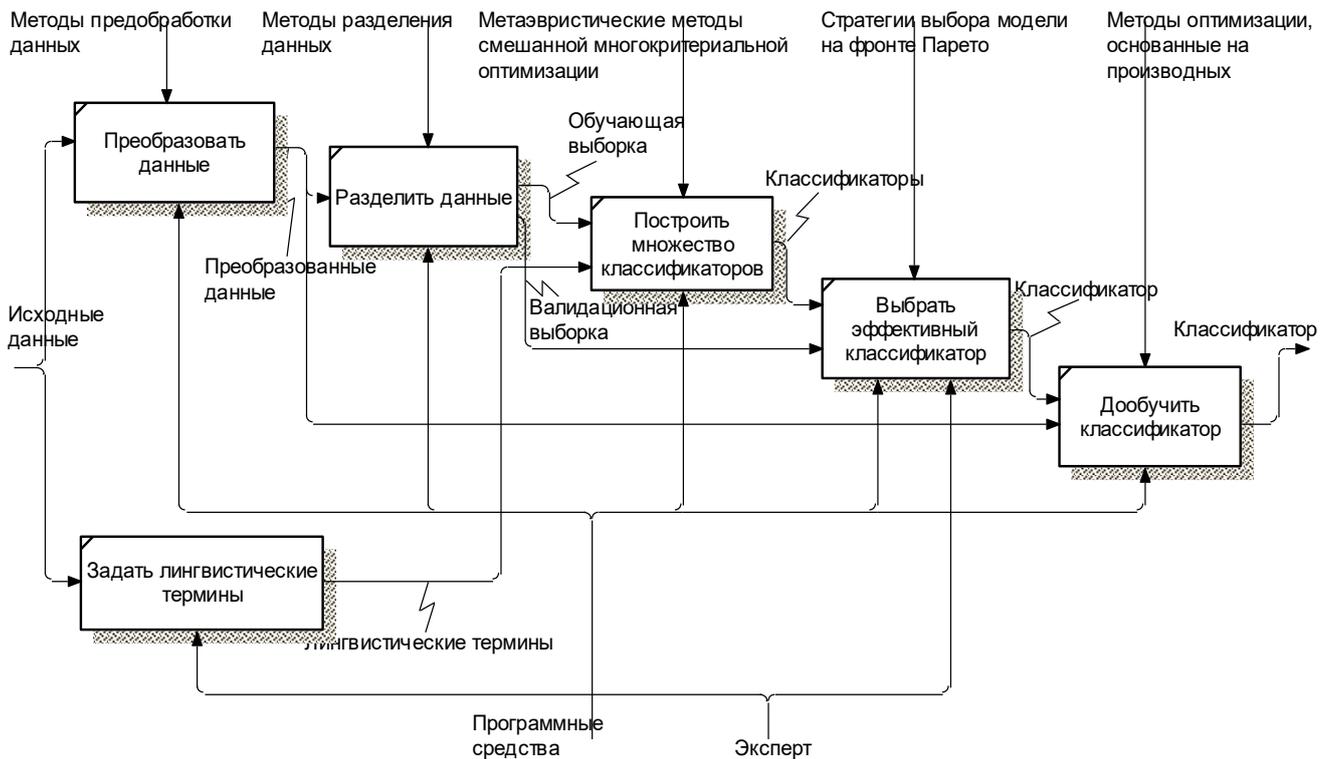


Рисунок 1 – Диаграмма IDEF0 методологии построения интерпретируемых нечетких классификаторов

Алгоритм MICS основан на метаэвристике «кукушкин поиск» и генетическом алгоритме. Компоненты вектора поиска, соответствующие непрерывным переменным, предлагается подбирать с помощью алгоритма «кукушкин поиск», а дискретные – с помощью генетического оператора скрещивания. Такое применение обусловлено тем, что алгоритмы роевого интеллекта демонстрируют лучшие результаты поиска в непрерывном пространстве. Генетические алгоритмы, наоборот, в своей стратегии не используют аспекты, связанные с расстоянием, и операторы алгоритма, согласно метафоре, работают в дискретном пространстве.

На рисунке 2 представлена схема предлагаемого алгоритма. Итерационный процесс начинается с генерации новых решений, после которого проводится их обновление. Далее извлекаются лучшие решения, необходимые для генерации

новых решений на следующей итерации. После обновления текущей популяции с помощью рангов недоминируемой сортировки и сортировки разреженности начинается новая итерация. Процесс повторяется заданное число раз. После завершения из популяции извлекаются недоминируемые решения.

Ниже представлено пошаговое описание алгоритма.

*Вход:* Размер популяции  $N$ , число итераций  $MaxIter$ , вероятность удаления гнезда  $p_a$ .

*Выход:*  $R$  – множество решений фронта Парето.

*Начало*

*Шаг 1.* Инициализация.

Случайным образом сгенерировать популяцию решений  $Pop = \{Pop_1, Pop_2, \dots, Pop_N\}$ . Популяция новых решений  $Pop^{new} = \{\emptyset\}$ . Инициализировать популяцию лучших решений  $Pop^{best} = Pop$ . Значения целевых функций популяции  $Pop$  установить в максимум  $f_{ij}^{pop} = \infty$ , где  $i = 1, \dots, N, j = 1, \dots, m$ .

*Шаг 2.* Инициализировать счетчик итераций  $t = 1$ .

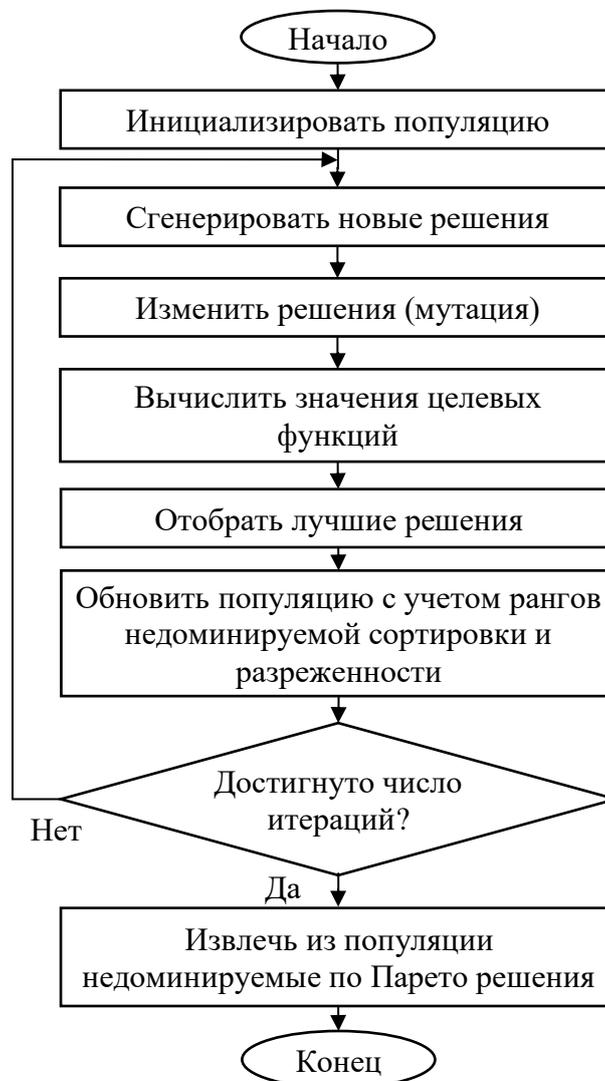


Рисунок 2 – Блок-схема алгоритма MICS

### Шаг 3. Генерация новых решений.

Формируется популяция новых решений  $Pop^{new}$  на основе  $Pop$  и  $Pop^{best}$ .

Для элементов векторов решений, которые соответствуют дискретным значениям, применить генетический оператор скрещивания над  $Pop$  и  $Pop^{best}$ . В настоящей работе применялось равномерное скрещивание, когда значение гена потомка выбирается случайным образом от соответствующих генов родителей. Схема представлена на рисунке 3.

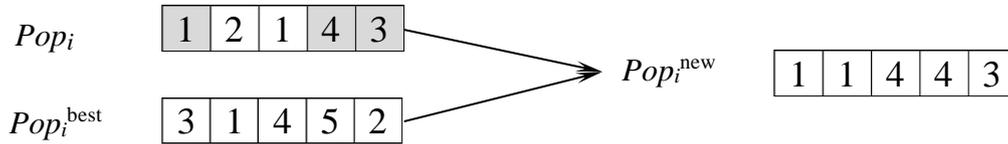


Рисунок 3 – Генерация дискретных элементов нового вектора решений

Для элементов векторов решений, которые соответствуют вещественным значениям, выполнить «случайное перемещение кукушки». Текущее значение изменить на величину полета Леви ( $Levi$ ), размер области поиска определяется расстоянием до лучшего решения из  $Pop^{best}$ :

$$Pop_i^{new} = Pop_i + Levi(0,1 \cdot (Pop_i^{best} - Pop_i)),$$

где  $i = 1, \dots, N$ .

### Шаг 4. Изменения решения (Мутация).

Изменение значения некоторых элементов  $Pop^{new}$ .

Изменить значения элементов векторов решений  $Pop^{new}$  с вероятностью  $p_a$ . Новые значения выбираются случайным образом из области значений элемента вектора. Данный шаг аналогичен оператору мутации генетического алгоритма.

### Шаг 5. Вычислить значения целевых функций для каждого решения $Pop^{new}$ .

$$f_{ij}^{new} = f_j(Pop_i^{new}),$$

где  $i = 1, \dots, N, j = 1, \dots, m$ ;  $f_j(\cdot)$  –  $j$ -я целевая функция.

### Шаг 6. Отбор лучших решений на фронте Парето (Селекция).

Формируется множество лучших решений  $Pop^{best} = \{Pop_1^{best}, Pop_2^{best}, \dots, Pop_N^{best}\}$ .

Для популяции  $Pop \cup Pop^{new}$  на основе значений целевых функций  $f^{new}$  и  $f^{pop}$  определить ранг Парето с помощью недоминируемой сортировки и ранг разреженности  $rank_c$  каждого элемента. Сформировать из элементов фронта Парето  $F_1 = \{b_1, b_2, \dots, b_k\}$  множество из  $N$  решений  $Pop^{best} = \{Pop_1^{best}, Pop_2^{best}, \dots, Pop_N^{best}\}$ . Поскольку предпочтения отдаются решениям с высшим рангом разреженности, то в качестве инструмента выбора может быть применена, например, рулеточная селекция. Вероятность выбора решения  $b_i$  ( $i=1, \dots, k$ ) из  $F_1$  в  $Pop^{best}$  в таком случае может быть рассчитана следующим образом:

$$P(b_i) = \frac{2(k - rank_c(b_i))}{k(k+1)}.$$

*Шаг 7. Обновление популяции.*

Обновить популяцию  $Pop$  с учетом новых решений  $Pop_{new}$ . Схема процедуры обновления представлена на рисунке 4. Новую популяцию  $Pop$  будут составлять  $N$  решений из множества  $Pop \cup Pop_{new}$ , которое содержит  $2 \cdot N$  элементов. Решения выбираются согласно рангам недоминирования Парето. Сначала извлекаются решения  $F_1$ , затем  $F_2$  и т.д.. Если в процессе извлечения получилось так, что выбрана только часть какого-либо множества  $F_i$  (на рисунке 4 это множество  $F_3$ ), то извлекаться должны решения, имеющие высший ранг разреженности. То есть решения из  $F_i$  выбираются согласно сортировке разреженности. После необходимо обновить значения целевых функций  $f^{pop}$  согласно новым элементам популяции  $Pop$ .

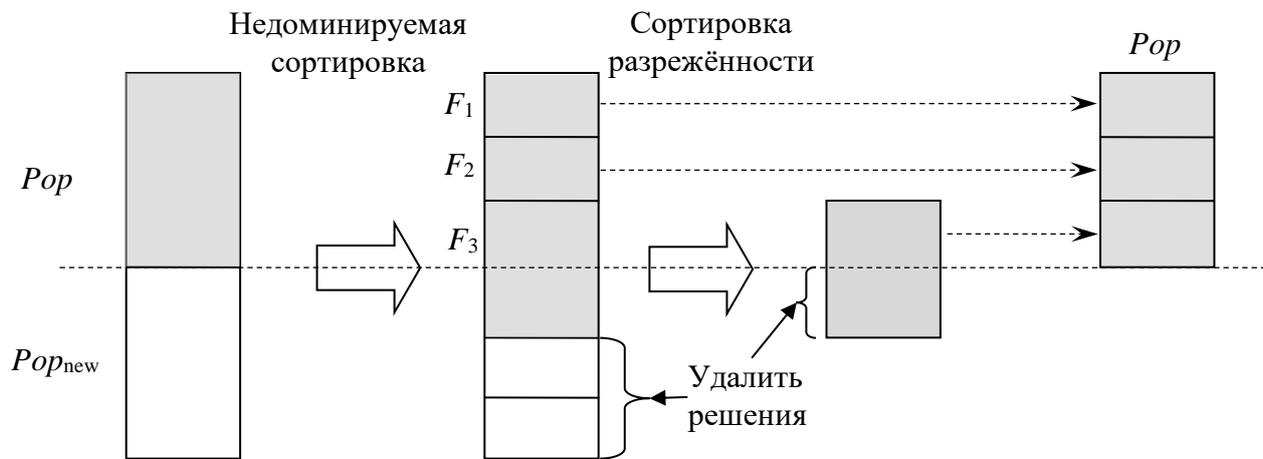


Рисунок 4 – Обновление популяции с помощью недоминируемой сортировки и сортировки разреженности<sup>1</sup>

*Шаг 8. Проверка остановки алгоритма.*

Если  $t < MaxIter$  то  $t = t + 1$  и перейти на *Шаг 3*, иначе перейти на *Шаг 9*.

*Шаг 9. Извлечь в  $R$  недоминируемые решения из популяции  $Pop$ .*

*Конец*

*Дискретный алгоритм оптимизации* на основе распределения вероятностей с трансформацией целевых значений PDT (Probability Distribution with Transformation) осуществляет поиск оптимума в дискретном пространстве. В основе алгоритма лежит формирование распределений вероятностей для значений переменных вектора поиска. Данные распределения используются в генерации новых решений и формируют направление поиска.

Разработанный дискретный алгоритм является итерационным, где на каждой итерации формируется вероятностная модель. Модель определяет вероятность появления каждого из дискретных значений для переменной на основе частоты появления данного значения среди решений популяции, причем меньшее значение целевой функции должно увеличивать вклад решения в повышение вероятности.

<sup>1</sup> Deb K. A fast and elitist multiobjective genetic algorithm: NSGA-II / K. Deb, S. Agrawal, A. Pratap, T. Meyarivan // IEEE Transactions on Evolutionary Computation. – 2002. – Vol. 6. – P. 182–197.

Для этого вводятся трансформационные функции, которые переводят значение целевой функции решения популяции в весовой коэффициент. На рисунке 5 представлена схема алгоритма.



Рисунок 5 – Схема алгоритма PDT

На этапе инициализации определяется начальная популяция решений  $P_{op}$  случайным или иным образом. Далее рассчитываются весовые коэффициенты решений популяции  $w$ . Весовой коэффициент принимает значение из диапазона  $[0, 1]$ , чем меньше целевое значение решения, тем больше значение  $w$ . Для того чтобы сформировать весовые коэффициенты из целевых значений предлагается использовать функции трансформации. В качестве таких функций, например, могут быть использованы следующие:  $T_L$  – линейная функция,  $T_S$  – сигмоида,  $T_Q$  – квадратичная функция,  $T_H$  – гиперболический тангенс. Графики функций представлены на рисунке 6. Область определения функций ограничена отрезком

$[f_{\min}, f_{\max}]$ , где  $f_{\min}$  и  $f_{\max}$  – максимальное и минимальное значения целевой функции в популяции.

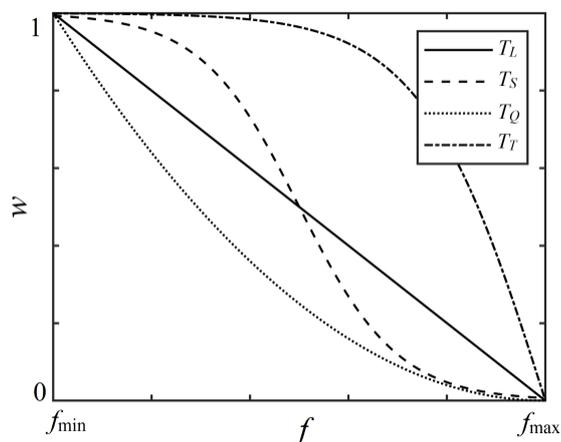


Рисунок 6 – Графики функций трансформаций для перевода целевых значений в веса решений

Ниже представлено пошаговое описание алгоритма.

*Вход:* Размер популяции  $N$ , число итераций  $MaxIter$ , вероятность мутации  $p_a$ , функция трансформации  $T$ . Обозначим  $l_{jk}$   $k$ -е дискретное значение  $j$ -й переменной.

*Выход:*  $R$  найденное решение.

*Начало*

*Шаг 1.* Инициализация.

Случайным или иным образом сгенерировать популяцию решений  $Pop = [Pop_1, Pop_2, \dots, Pop_N]$  и вычислить соответствующее целевое значение  $f = [f_1, f_2, \dots, f_N]$ .

*Шаг 2.* Инициализировать счетчик итераций  $t = 1$ . Начало итерационного процесса.

*Шаг 3.* Вычислить весовые коэффициенты решений популяции  $Pop$  с помощью функции трансформации  $T$ :  $w_i = T(f_i)$ , где  $i = 1, \dots, N$ .

*Шаг 4.* Вычислить распределения вероятностей.

Для каждого дискретного значения  $k$  переменной  $j$  определить сумму весовых коэффициентов решений  $Pop$ , которые принимают данное дискретное значение  $k$ . Обозначим такую сумму  $S_{jk}$ , где  $j = 1, \dots, n$ ,  $k = 1, \dots, m$ .

$$S_{jk} = \sum_{i=1}^N w_i \cdot \begin{cases} 1, & \text{если } Pop_{ij} == l_{jk} \\ 0, & \text{иначе} \end{cases}.$$

Вычислить эмпирическую вероятность появления  $k$ -го значения переменной  $j$ :

$$P_{jk} = \frac{S_{jk}}{\sum_{k=1}^m S_{jk}}.$$

*Шаг 5.* Сгенерировать новые решения.

Формируется популяция новых решений  $Pop^{new}$  на основе вероятностей  $P$  каждой переменной:

$$Pop_{ij}^{new} = l_{jk},$$

где  $k$  удовлетворяет условию  $p_{k-1} < rand(0,1) \leq p_k$ ,

$$p = \left[ 0, P_{j1}, P_{j1} + P_{j2}, \dots, \sum_{k=1}^m P_{jm} \right],$$

$j = 1, \dots, n; k = 1, \dots, m$ .

*Шаг 6.* Изменить новые решения (Мутация).

Изменить значения элементов векторов решений  $Pop^{new}$  с вероятностью  $p_a$ . Новые значения выбираются случайным образом из области значений элемента вектора решений.

*Шаг 7.* Вычислить значение целевых функций  $f_i^{new}$ , где  $i = 1, \dots, N$ , для каждого решения  $Pop^{new}$ .

*Шаг 8.* Обновить популяцию  $Pop$  путем выбора  $N$  лучших решений из множества решений  $Pop \cup Pop^{new}$ . Обновить значения целевых функций  $f_i$  согласно решениям  $Pop$ .

*Шаг 9.* Проверка остановки алгоритма.

Если  $t < MaxIter$  то  $t = t + 1$  и перейти на *Шаг 3*, иначе перейти на *Шаг 10*.

*Шаг 10.* Извлечь в  $R$  лучшее решение из популяции  $Pop$ .

*Конец*

*Адаптированный алгоритм градиентного спуска* разработан для настройки параметров нечетких классификаторов, построенных метаэвристическими методами. Современные методы построения нечетких классификаторов отдают предпочтение метаэвристическим алгоритмам, поскольку способны осуществлять поиск глобального оптимума, в отличие от детерминированных, которые сосредоточены на локальном поиске. Также данные алгоритмы не требуют анализа целевой функции и ее дифференцируемости, что является затруднительным для нечетких классификаторов. Фактически целевая функция представляется «черным ящиком», для которого определяются только входные и выходные значения. В алгоритмах, основанных на дифференцировании, точность поиска локального оптимума в окрестности заданной точки значительно выше. Поэтому комбинированный поиск на основе метаэвристического и детерминированного алгоритмов потенциально может повысить эффективность поиска глобального оптимума.

В качестве целевой функции оптимизации предложена сумма квадратов отклонений нормированных значений разделяющих функций от их ожидаемых значений:

$$E = \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^M \left( \frac{g_k(\mathbf{x}_p)}{\sum_{k=1}^c g_k(\mathbf{x}_p)} - y_{pk} \right)^2,$$

где  $(\mathbf{x}_p, l_p)$  –  $p$ -й образец исходных данных  $Data$ ,  $y_{pk}$  – ожидаемое значение разделяющей функции  $k$ -го класса для  $p$ -го образца. Если образец принадлежит классу  $\omega_h$ , то  $y_{pk} = 1$  для  $k = h$  и  $y_{pk} = 0$  для  $k \neq h$ . Нормирование проводится для корректировки значения разделяющих функций в диапазон  $[0, 1]$ .

Вектор решения содержит значения параметров функций принадлежности нечетких терминов, используемых в классификаторе:  $\mathbf{P} = (s_1, s_2, \dots, \sigma_1, \sigma_2, \dots)$ . Градиент, с помощью которого определяется направление изменения вектора решений на итерациях алгоритма, имеет следующий вид:

$$\nabla E(\mathbf{P}) = \left( \frac{\partial E}{\partial s_1}, \frac{\partial E}{\partial s_2}, \dots, \frac{\partial E}{\partial \sigma_1}, \frac{\partial E}{\partial \sigma_2}, \dots \right).$$

Схема алгоритма приведена на рисунке 7. Для поиска минимума целевой функции  $E$ , необходимо изменять параметры нечеткого классификатора в направлении противоположном направлению градиента. Причем при изменении параметры не должны выйти за границы их значений. Границы задаются до выполнения работы алгоритма. На схеме верхняя граница обозначена вектором  $\mathbf{U} = (U_1, U_2, \dots)$ , а нижняя – вектором  $\mathbf{L} = (L_1, L_2, \dots)$ . Если найденные решения выходят за границы требуемого диапазона, то они принимают граничные значения. Сам спуск является итерационным процессом, в котором  $\mathbf{P}$  изменяется следующим образом:

$$\mathbf{P} = \mathbf{P} - h \nabla E(\mathbf{P}), \quad (2)$$

где  $h$  – длина шага в направлении спуска, которая выбирается методом дробления, т.е. итерации по формуле (2) проводятся до тех пор, пока функция  $E$  убывает и не уменьшается точность классификации  $acc(\mathbf{P})$  в связи с изменением параметров функций принадлежности. Если убывание прекращается или точность уменьшается, то шаг  $h$  уменьшается вдвое, вычисляются элементы  $\mathbf{P}$  с новым шагом и снова проверяется условие. Дробление шага продолжается до тех пор, пока не будет выполнено условие. Итерационный процесс прекращается по достижению длины шага  $h$  минимального допустимого значения  $\epsilon$ , которое задается до выполнения работы алгоритма.

*Метод разделения данных для построения прогностических моделей машинного обучения.* Для построения моделей машинного обучения с высокой прогностической способностью исходные данные разделяют на обучающую и валидационную выборки. С помощью обучающей выборки строятся множество моделей, обычно имеющих разную структурную сложность. С помощью валидационной выборки из полученного множества выбирается модель с лучшей прогностической способностью (рисунок 8).

Обычно разделение проводят случайным образом, что может повлечь потерю важной информации для моделирования наблюдаемого процесса или явления, особенно при малом количестве образцов. Это негативно отражается на обобщающей способности прогностической модели. Необходимо сохранить близость выборок к исходным данным. Под близостью в работе подразумевается минимальное отклонение характеристик полученных выборок от исходных

данных. В качестве таких характеристик используются среднее значение и среднеквадратичное отклонение признаков данных. Разработанный метод позволяет провести разделение данных с сохранением близости с помощью сведения данной задачи к бинарной оптимизации. Для того чтобы минимизировать отклонение характеристик признаков в методе применяется бинарный алгоритм оптимизации, который формирует обучающую и валидационную выборки, близкие к исходной.

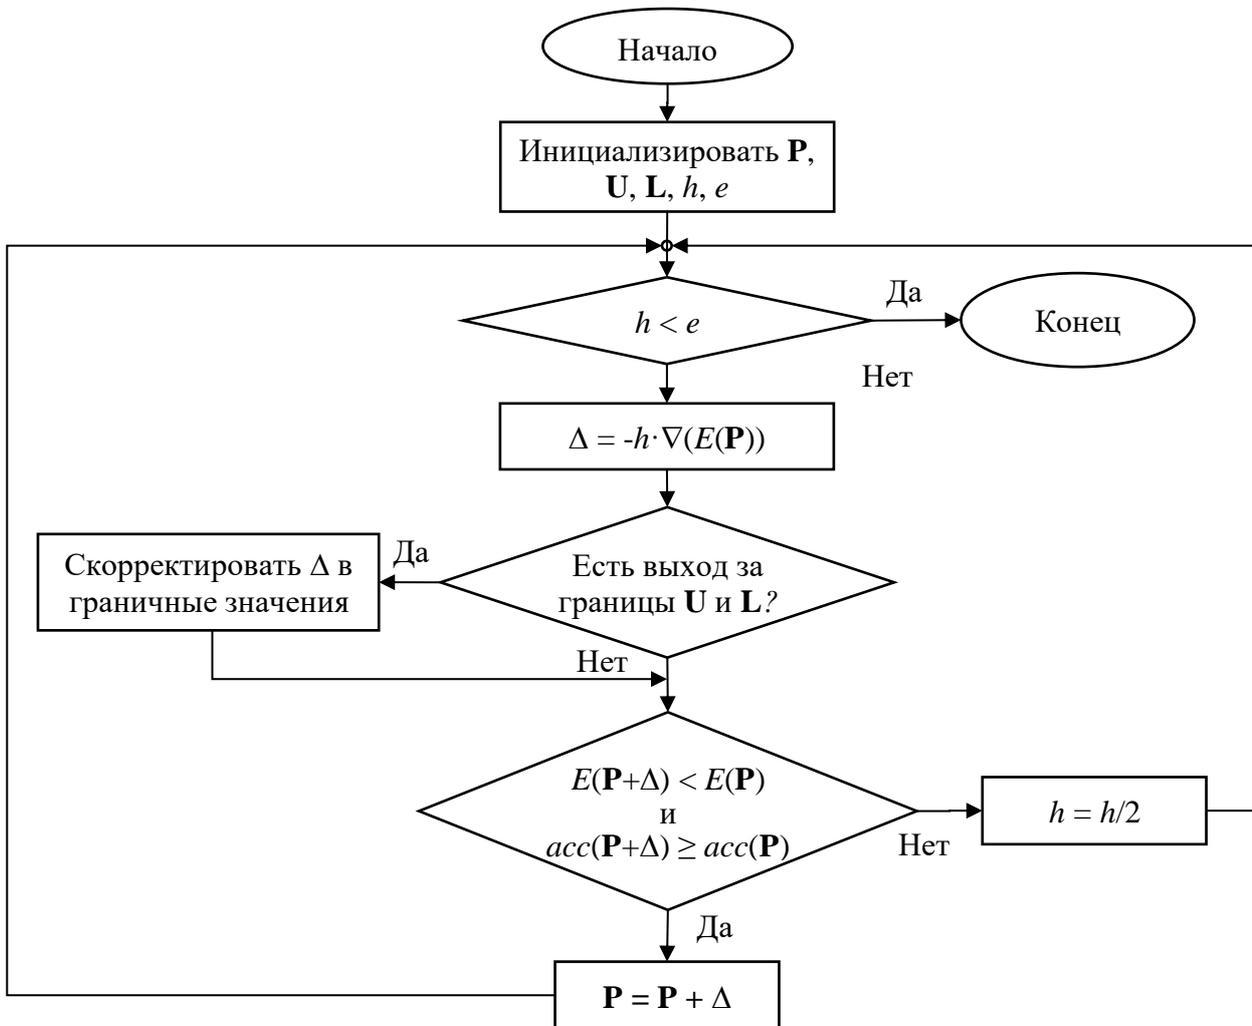


Рисунок 7 – Схема алгоритма градиентного спуска для настройки параметров нечетких классификаторов

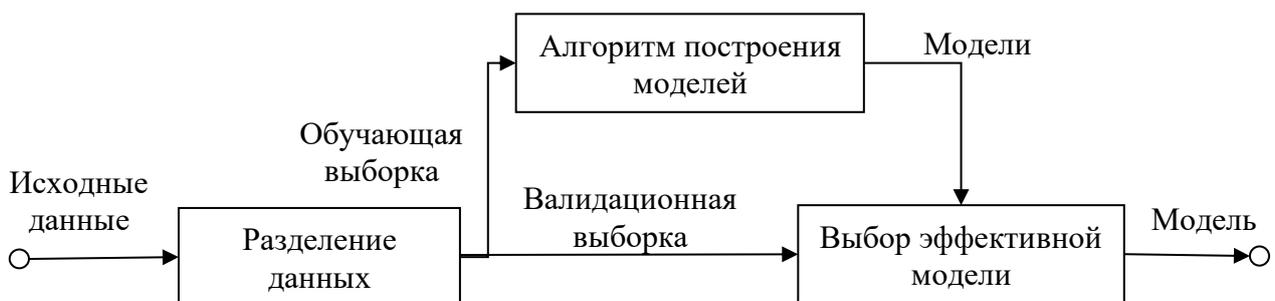


Рисунок 8 – Схема построения прогностических моделей с разделением данных

С каждой переменной вектора решений оптимизации связан образец исходных данных. Чтобы закодировать к какой выборке относится образец, условимся, что переменные могут принимать значение 0 или 1. Если значение переменной 0, то соответствующий образец будет включен в обучающую выборку, а если 1, то в валидационную (рисунок 9). Количество элементов в векторе будет соответствовать числу образцов исходных данных.

Образец 1	Образец 2	Образец 3	Образец 4	Образец 5	Образец 6	Образец 7	...	Образец <i>m</i>
1	1	0	0	1	1	0	...	0

Рисунок 9 – Вектор поиска в методе разделения данных

В алгоритме векторы решений популяции после генерации подвергаются изменениям для удовлетворения ограничений, накладываемых на полученные обучающие и валидационные выборки. Ограничения связаны с удовлетворением отношения между количеством образцов получаемых выборок, которое должно быть фиксированным и задаваться до начала выполнения метода.

В работе предложено четыре варианта целевых функций для бинарной оптимизации. Лучший результат при построении нечетких классификаторов продемонстрировала функция на основе максимального суммарного отклонения характеристик признаков обучающей выборки от исходных данных:

$$\varphi = \max_{j=1, \dots, n} \left( \frac{|F_1(X_j^{tra}) - F_1(X_j)|}{x_j^{\max} - x_j^{\min}} + \frac{|F_2(X_j^{tra}) - F_2(X_j)|}{x_j^{\max} - x_j^{\min}} \right),$$

где  $X_j$ ,  $X_j^{tra}$  – множества значений  $j$ -й переменной исходной и обучающей выборок соответственно ( $j=1, \dots, n$ );  $F_1(X)$  – среднее значение  $X$ ;  $F_2(X)$  – среднеквадратичное отклонение  $X$ ;  $x_j^{\max}$  и  $x_j^{\min}$  – максимальное и минимальное значения множества  $X_j$ .

*Методика построения интерпретируемых нечетких классификаторов.* На основе методологии предложена методика построения интерпретируемых нечетких классификаторов (рисунок 10), использующая разработанные алгоритмы оптимизации и метод разделения данных. Исходными данными методики является размеченная выборка данных *Data* (1). Результатом выполнения методики является построенный классификатор *Fis*. Сначала данные *Data* подвергаются нормированию, путем сведения значений всех признаков к интервалу [0, 1]. Далее применяется метод разделения данных для получения обучающей *tra* и валидационной *val* выборок, близких по статистическим характеристикам к исходной *Data*. В качестве алгоритма бинарной оптимизации для разделения данных в методе используется дискретный алгоритм оптимизации PDT. После разделения данных проводится построение недоминируемого по критериям точности и интерпретируемости множества нечетких классификаторов с помощью метаэвристического алгоритма смешанной многокритериальной оптимизации MICS. Из множества построенных классификаторов выбирается классификатор *Fis*

с лучшей точностью на исходных данных *Data* и проводится оптимизация параметров его функций принадлежности адаптированным алгоритмом градиентного спуска.

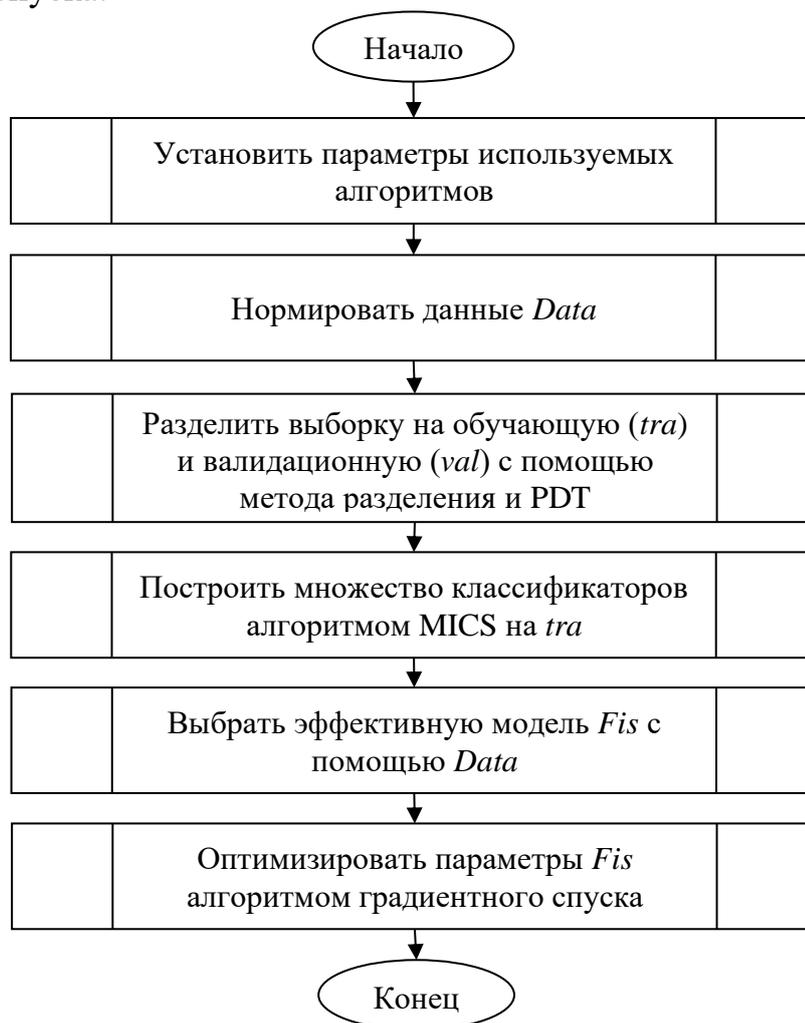


Рисунок 10 – Схема методики построения нечетких классификаторов

Рассмотрим построение классификаторов с помощью алгоритма смешанной многокритериальной оптимизации. Исходными данными алгоритма являются обучающие данные *tra*. На выходе – полученные алгоритмом классификаторы, которые образуют множество недоминируемых решений по критериям точности и интерпретируемости. Далее будет показано, каким образом построение классификаторов сводится к задаче смешанной многокритериальной оптимизации.

Пространство каждой переменной разделяется на нечеткие множества, количество которых для каждого признака задается экспертом до построения классификаторов и представляет вектор  $\mathbf{h} = (h_1, h_2, \dots, h_n)$ , где  $h_i$  – количество нечетких множеств для  $i$ -й переменной ( $i = 1, \dots, n$ ). С каждым нечетким множеством ассоциируется нечеткий термин, употребляемый в базе правил для оценки значения признака. Нечеткие множества определяются равномерным покрытием пространства признака, что обеспечивает их высокую интерпретируемость в лингвистические термины. Для достижения лучшей точности классификации предлагается осуществлять небольшие сдвиги параметров функций принадлежности. Для этого вводятся боковое смещение  $\alpha$  и смещения охвата  $\beta$ . На

рисунке 11 продемонстрированы такие смещения для функции принадлежности нечеткого термина «Среднее».

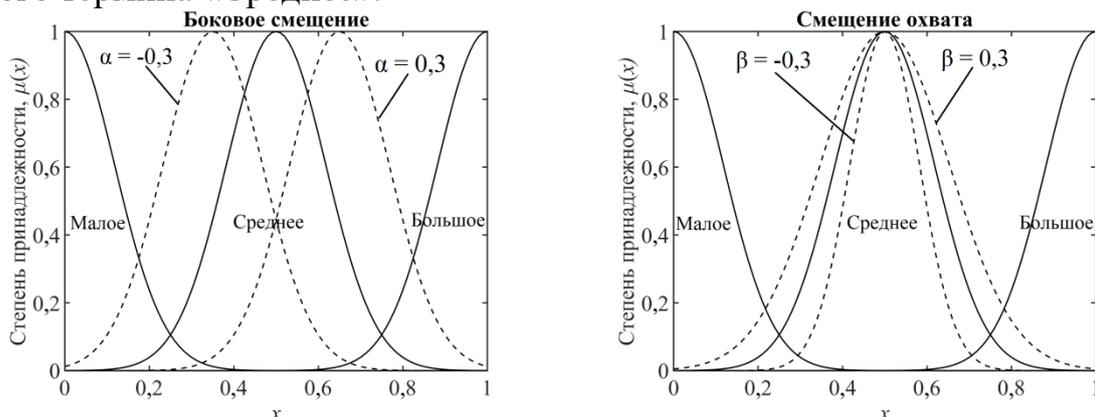


Рисунок 11 – Изменения функции принадлежности нечеткого множества «Среднее» при боковом смещении и смещении охвата

Чтобы получить значения параметров функций принадлежности с учетом введенных смещений необходимо провести следующие преобразования:

$$s_{ij} = \frac{x_i^{\max} - x_i^{\min}}{h_i - 1} (j - 1 + \alpha_{ij})$$

$$\sigma_{ij} = \frac{(x_i^{\max} - x_i^{\min})}{3(h_i - 1)} \left( 1 + \frac{\beta_{ij}}{h_i} \right), \quad (3)$$

где  $s_{ij}$ ,  $\sigma_{ij}$  – среднее значение и среднеквадратичное отклонение функции принадлежности  $i$ -й переменной  $j$ -го термина;  $\alpha_{ij}$ ,  $\beta_{ij}$  – соответствующие боковое смещение и смещение охвата;  $x_i^{\min}$ ,  $x_i^{\max}$  – минимальное и максимальное значение  $i$ -й переменной в исходном наборе данных;  $i = 1, \dots, n$ ;  $j = 1, \dots, h_j$ .

Параметры  $\alpha$  и  $\beta$  при малых значениях инициируют малые сдвиги, что не существенно отражается на потере интерпретируемости. В настоящей работе оба смещения изменяются в диапазоне  $[-0,3, 0,3]$ . С помощью выражений (3) они преобразуются в параметры функции принадлежности.

Вектор решений оптимизации кодирует классификатор и состоит из переменных, описывающих структурные и параметрические характеристики. Вектор разделен на две части – целочисленную и вещественную (рисунок 12). В целочисленной части представлена структура классификатора. Каждый элемент связан с переменной правила и содержит целочисленный код нечеткого множества согласно равномерному разделению. Помимо нечеткого множества, элемент вектора может содержать код 0, обозначающий отсутствие переменной в правиле. В случае разделения пространства признака на три нечетких множества (рисунок 11) элемент вектора принимает значение из множества  $\{0, 1, 2, 3\}$ , где «0» указывает на отсутствие переменной в правиле, «1» соответствует термину «Малое», «2» – «Среднее», «3» – «Большое». Элементы разбиты на группы, представляющие одно правило. Порядок нечетких множеств в группах следует порядку переменных образцов данных. Обозначение  $\mu_{ij}$  на рисунке соответствует

коду функции принадлежности  $i$ -й переменной  $j$ -го правила, где  $i = 1, \dots, n, j = 1, \dots, r$ . Параметр  $r$  указывает на максимально возможное число правил в классификаторе и задается до запуска алгоритма. Размер целочисленной части соответствует  $nr$  элементам.

Вещественная часть вектора решений содержит боковые смещения и смещения охвата каждого нечеткого множества. Элементы со смещениями чередуют друг друга (рисунок 12). Обозначение  $\alpha_{ij}$  и  $\beta_{ij}$  на рисунке соответствуют боковому смещению и смещению охвата  $i$ -й переменной  $j$ -го нечеткого множества, где  $i = 1, \dots, n, j = 1, \dots, h_i$ . Размер вещественной части составляет  $2(h_1+h_2+\dots+h_n)$  элементов. Размер всего вектора поиска составляет  $(nr + 2(h_1+h_2+\dots+h_n))$  элементов.



Рисунок 12 – Структура вектора решений алгоритма смешанной оптимизации

Для того чтобы обеспечить компромисс «точность–интерпретируемость» в работе алгоритма смешанной многокритериальной оптимизации предлагается использовать три целевых значения, а именно: точность классификации ( $acc$ ), количество правил ( $\#R$ ) и общее количество используемых в базе правил нечетких терминов ( $\#C$ ). Первый показатель должен быть максимизирован, два последних – минимизированы. Таким образом, построение классификатора сводится к задаче многокритериальной смешанной оптимизации следующего вида:

$$\left\{ \begin{array}{l} acc(\mathbf{V}) \rightarrow \max \\ \#R(\mathbf{V}) \rightarrow \min \\ \#C(\mathbf{V}) \rightarrow \min \\ v_i \in \{0, 1, \dots, h_j\}, 1 \leq i \leq nr, j = \begin{cases} n, & \text{если } \text{mod}(i, n) = 0 \\ \text{mod}(i, n), & \text{иначе} \end{cases} \\ v_i \in [-0, 3, 0, 3], nr + 1 \leq i \leq nr + 2(h_1 + \dots + h_n) \end{array} \right. ,$$

где  $\mathbf{V} = (v_1, v_2, \dots, v_{(nr+2(h_1+\dots+h_n))})$  – вектор решения.

**В третьем разделе** представлены вычислительные эксперименты разработанных алгоритмов, метода разделения данных и методики построения нечетких классификаторов, чтобы оценить их эффективность и провести сравнения с аналогами. Работа алгоритма смешанной многокритериальной оптимизации и дискретного алгоритма оценивалась с помощью тестовых функций, используемых

для оценки эффективности оптимизационных алгоритмов. Метод разделения данных применялся для построения нечетких классификаторов различных предметных областей, где проведена оценка точности и интерпретируемости полученных моделей. Эффективность адаптированного алгоритма градиентного спуска оценивалась точностью нечетких классификаторов, параметры которых корректировались после построения алгоритмом смешанной многокритериальной оптимизации. В заключении представлены эксперименты методики построения нечетких классификаторов, которая включает в себя вышеприведенные алгоритмы и метод разделения. Для того чтобы оценить значимость различий критериев эффективности с аналогами, применены статистические тесты.

В вычислительном эксперименте по построению нечетких классификаторов применялись 38 наборов данных из репозитория KEEL<sup>2</sup>. Три набора являются синтетическими, специально разработанными для проверки эффективности классификаторов, остальные собраны из реальных проблемных областей. Количество образцов в наборах варьировалось в диапазоне 109–19020, количество признаков 2–90, количество классов 2–15. Методика проведения экспериментов осуществлялась по схеме 10-кратной перекрестной проверки и соответствует методике *M. Fazolari et al.*<sup>3</sup> и *J. Alcalá-Fdez et al.*<sup>4</sup>. Для каждого из 10 разбиений построение осуществляется три раза. Таким образом, эффективности оценивалась средним значением по тридцати запускам метода на каждом наборе данных. Вычислялись показатель точности – процент правильно классифицированных образцов, показатели интерпретируемости – количество правил, количество признаков, общее количество нечетких терминов в базе правил, среднее количество нечетких терминов в antecedентной части правила. Согласно данной методике, оценивалась эффективность альтернативных методов.

*Вычислительный эксперимент алгоритма смешанной многокритериальной оптимизации.* Для оценки эффективности метаэвристического алгоритма смешанной многокритериальной оптимизации MICS применялась методика, предложенная *W. Wang et al.*<sup>5</sup>. Работа алгоритма проверялась с помощью модифицированных тестовых функций ZDT и DTLZ, в которые включены непрерывные и дискретные переменные. Для сравнения проведены эксперименты генетического алгоритма с недоминируемой сортировкой NSGAII.

---

<sup>2</sup> <http://keel.es>

<sup>3</sup> Fazzolari M. Multi-objective evolutionary method for learning granularities based on fuzzy discretization to improve the accuracy-complexity trade-off of fuzzy rule-based classification systems: D-MOFARC algorithm / M. Fazzolari, R. Alcalá, F. Herrera // *Applied Soft Computing*. – 2014. – Vol. 24. – P. 470-481.

<sup>4</sup> Alcalá-Fdez J. A Fuzzy Association Rule-Based Classification Model for High-Dimensional Problems With Genetic Rule Selection and Lateral Tuning / J. Alcalá-Fdez, R. Alcalá, F. Herrera // *IEEE Transactions on Fuzzy Systems*. – 2011. – Vol. 19, No. 5. – P. 857–872.

<sup>5</sup> Wang W. An improved estimation of distribution algorithm for multi-objective optimization problems with mixed-variable / W. Wang, K. Li, H. Jalil, H. Wang // *Neural Computing and Applications*. – 2022. – Vol. 34. – P. 19703-19721.

Эффективность оценивалась с помощью двух критериев. Первый – обратное расстояние поколений (inverted generational distance,  $IGD$ ):

$$IGD = \frac{\sum_{v \in PF} d(v, U)}{|PF|},$$

где  $PF$  – множество точек целевого пространства, образующих фронт Парето и являющихся оптимумом тестовых функций;  $U$  – множество точек целевого пространства, соответствующих результату работы алгоритма;  $d(v, U)$  – минимальное евклидово расстояние между точкой  $v$  и множеством точек  $U$ .

Второй критерий – степень доминирования (dominate ratio,  $DR$ ). Это относительный показатель, рассчитываемый при сравнении алгоритмов оптимизации. Допустим, сравниваются  $k$  алгоритмов многокритериальной смешанной оптимизации. Каждый алгоритм возвращает множество решений  $U_1, U_2, \dots, U_k$ . Объединим результаты оптимизации всех алгоритмов в одно множество  $U = U_1 \cup U_2 \cup \dots \cup U_k$  и выделим из него множество недоминируемых решений  $U'$ . Степень доминирования  $i$ -го алгоритма определяет процентный состав решений  $U'$  входящих в  $U_i$

$$DR_i = \frac{|U_i \cap U'|}{|U'|} \cdot 100\%,$$

где  $i = 1, \dots, k$ . Фактически этот показатель определяет соотношение доминирования по Парето среди наборов решений всех сравниваемых алгоритмов. Чем больше значение, тем выше эффективность оцениваемого алгоритма.

Результаты сравнения теста знаковых рангов Уилкоксона приведены в таблице 1. Нулевая гипотеза теста  $H_0$  утверждает отсутствие значимых различий (на уровне  $\alpha=0,05$ ) в оценках эффективности сравниваемых алгоритмов, а альтернативная  $H_1$  утверждает обратное. Предложенный алгоритм MICS продемонстрировал значимый прирост эффективности на комплексных оценках сходимости и многообразия, таких как степень доминирования и обратное расстояние поколений, по сравнению с генетическим алгоритмом NSGAII. Значение  $IGD$  в среднем оказалось меньше на 95,47%. Степень доминирования оказалось больше в среднем на 70,92%.

Таблица 1 – Статистическое сравнение алгоритмов MICS и NSGAII по критериям  $IGD$  и  $DR$

Критерий	Доля дискретных переменных	Сумма рангов		$p$ -value	Гипотеза $H_0$
		+	-		
$IGD$	0,2	3	133	<0,001	Отклоняется
	0,5	16,5	119,5	0,0078	Отклоняется
	0,8	18	118	0,0096	Отклоняется
$DR$	0,2	171	0	<0,001	Отклоняется
	0,5	171	0	<0,001	Отклоняется
	0,8	171	0	<0,001	Отклоняется

*Вычислительный эксперимент дискретного алгоритма оптимизации.* Для оценки эффективности проведен вычислительный эксперимент дискретного алгоритма в бинарном пространстве поиска, т.е. когда переменные принимают только два значения. В эксперименте применялись восемнадцать различных унимодальных и мультимодальных эталонных функций, широко применяемых для тестирования алгоритмов оптимизации. Для проведения эксперимента использовалась методика, предложенная *E. Bas* и *E. Ulker*<sup>6</sup>. Для сравнения эффективности также проведены эксперименты генетического алгоритма (GA) и бинарного алгоритма роящихся частиц (BPSO) в тех же условиях методики.

Эффективность работы алгоритмов оценивалась с помощью двух критериев. Первый оценивает сходимость алгоритма и определяется средним отклонением найденного целевого значения от фактического:

$$E = \frac{1}{n_{run}} \cdot \sum_{i=1}^{n_{run}} |f_i - f^*|,$$

где  $n_{run}$  – количество запусков алгоритма;  $f_i$  – найденное алгоритмом значение целевой функции в  $i$ -м запуске;  $f^*$  – фактическое значения оптимума целевой функции. Второй критерий оценивает стабильность работы недетерминированного алгоритма и определяется среднеквадратичным отклонением найденного значения целевой функции:

$$STD = \sqrt{\frac{1}{n_{run}} \sum_{i=1}^{n_{run}} (f_i - M)^2},$$

где  $M$  – среднее значение целевой функции.

Результаты статистического сравнения тестом знаковых рангов Уилкоксона (таблица 2) показали значимое улучшение (на уровне  $\alpha=0,05$ ) критериев эффективности по сравнению с альтернативными алгоритмами. В среднем отклонение от оптимума  $E$  уменьшилось в 4,3 раза по сравнению с GA и в 10,1 раза по сравнению с BPSO.

Таблица 2 – Статистическое сравнение PDT и альтернативных алгоритмов

Критерий	Альтернативный алгоритм	Сумма рангов		$p$ -value	Гипотеза $H_0(\alpha=0,05)$
		+	-		
$E$	GA	0	136	<0,001	Отклоняется
	BPSO	2	169	<0,001	Отклоняется
$STD$	GA	6	130	<0,001	Отклоняется
	BPSO	4	167	<0,001	Отклоняется

*Вычислительный эксперимент метода разделения данных.* Целью эксперимента является показать эффективность применения предлагаемого метода разделения данных при построении нечетких классификаторов по сравнению с

<sup>6</sup> Bas E. A binary social spider algorithm for continuous optimization task / E. Bas, E. Ulker // Soft Computing. – 2020. – Vol. 24. – P. 12953-12979.

построением без разделения, как предлагают *M. Fazolari et al.*<sup>3</sup> и *R. Alcalá et al.*<sup>7</sup>, где выбирается классификатор с лучшей точностью на обучающих данных. Кроме этого, показана эффективность метода по сравнению с разделением данных случайным образом. В эксперименте классификатор строился с помощью алгоритма смешанной многокритериальной оптимизации MICS, дискретный алгоритм PDT применялся для разделения данных на обучающую и валидационную выборки.

Результаты эксперимента позволили определить вид целевой функции для бинарной оптимизации при разделении данных, а также показали, что при выборе классификатора с лучшей прогностической способностью на фронте Парето нужно использовать все исходные данные. Статистическое сравнение тестом знаковых рангов Уилкоксона представлено в таблицах 3 и 4. Точность классификации обозначена *acc*, количество правил *#R*, количество признаков *#F*, общее количество нечетких терминов *#T*. Получен статистически значимый прирост точности и интерпретируемости (на уровне  $\alpha=0,05$ ) по сравнению с моделями без применения метода разделения данных. Максимальный прирост точности составил 6,5%.

Таблица 3 – Статистическое сравнение точности классификаторов (*acc*), построенных со случайным разделением исходных данных и с помощью метода разделения

Агрегация правил	Сумма рангов		<i>p</i> -value	Гипотеза $H_0$ ( $\alpha=0,05$ )
	+	–		
Максимум	171	570	0,00386	Отвергается
Сумма	165,5	575,5	0,00298	Отвергается

Таблица 4 – Статистическое сравнение показателей эффективности классификаторов, построенных без применения разделения данных и с применением метода разделения

Агрегация правил	Показатели эффективности	Сумма рангов		<i>p</i> -value	Гипотеза $H_0$ ( $\alpha=0,05$ )
		+	–		
Максимум	<i>acc</i>	192,5	548,5	0,00988	Отвергается
	<i>#R</i>	498,5	242,5	0,06288	Принимается
	<i>#T</i>	580,5	160,5	0,00228	Отвергается
	<i>#F</i>	408,5	152,5	0,02202	Отвергается
Сумма	<i>acc</i>	188,5	552,5	0,0083	Отвергается
	<i>#R</i>	562,5	178,5	0,00544	Отвергается
	<i>#T</i>	541,5	199,5	0,01314	Отвергается
	<i>#F</i>	412,5	148,5	0,01828	Отвергается

*Вычислительный эксперимент адаптированного алгоритма градиентного спуска.* Для оценки эффективности адаптированного алгоритма градиентного спуска проведен вычислительный эксперимент по настройке параметров функций

<sup>7</sup> Multiobjective genetic fuzzy rule selection of single granularity-based fuzzy classification rules and its interaction with the lateral tuning of membership functions / R. Alcalá, Y. Nojima, F. Herrera, H. Ishibuchi // Soft Computing. – 2011. – Vol. 15. – P. 2303–2318.

принадлежности нечетких классификаторов данным алгоритмом. Классификаторы предварительно были построены с помощью алгоритма смешанной многокритериальной оптимизации MICS. Статистическое сравнение точности классификации тестом знаков рангов Уилкоксона до и после применения градиентного спуска представлено в таблице 5. Получен статистически значимый прирост точности (на уровне  $\alpha=0,05$ ), максимальное значение которого составило 5,1%.

Таблица 5 – Статистическое сравнение точности классификации до и после применения адаптированного алгоритма градиентного спуска

Агрегация правил	Сумма рангов		<i>p</i> -value	Гипотеза $H_0$ ( $\alpha=0,05$ )
	+	-		
Максимум	21,5	644,5	<0,001	Отвергается
Сумма	75,5	590,5	<0,001	Отвергается

*Вычислительный эксперимент методики построения нечетких классификаторов.* В эксперименте проведена оценка точности классификации и интерпретируемости. Проведено сравнение с известными интерпретируемыми моделями машинного обучения, такими как генетические нечеткие системы FARC-HD<sup>4,8</sup> и деревья решений CART<sup>9</sup>.

Построение нечетких классификаторов FARC-HD осуществлялось с помощью программного обеспечения для анализа данных KEEL 3.0<sup>10</sup>. Параметры алгоритма построения выставлены в значения, рекомендованные разработчиками, и приведены в таблице 6. Использовались три нечетких термина на каждый признак для классификаторов FARC-HD и предлагаемой методики, что соответствует понимаемому человеку разделению на термины «Малое», «Среднее» и «Большое». Построение деревьев решений осуществлялось в среде MATLAB с помощью реализации алгоритма CART в библиотеке «Statistics and Machine Learning Toolbox». Параметры алгоритма подбирались с помощью байесовской оптимизации. Диапазон изменения параметров представлен в таблице 6. Параметры для проведения построения нечетких классификаторов с помощью предлагаемой методики представлены в таблице 7.

Сравнение точности классификации статистическим тестом знаковых рангов Уилкоксона представлено в таблице 8. Тест на уровне значимости  $\alpha = 0,05$  не

<sup>8</sup> Improving the Performance of FARC-HD in Multi-class Classification Problems Using the One-Versus-One Strategy and an Adaptation of the Inference System / M. Elkan, M. Galar, J. Sanz, E. Barrenechea, F. Herrera, H. Bustince // Communications in Computer and Information Science. – 2014. – Vol. 444. – P. 296–306.

<sup>9</sup> Coppersmith D. Partitioning Nominal Attributes in Decision Trees / D. Coppersmith, S. J. Hong, J. R. M. Hosking // Data Mining and Knowledge Discovery. – 1999. – Vol. 3. – P. 197-217.

<sup>10</sup> Triguero I. KEEL 3.0: An Open Source Software for Multi-Stage Analysis in Data Mining / I. Triguero, S. Gonzalez, J. M. Moyano, S. Garcia, J. Alcalá-Fdez, J. Luengo, A. Fernandez, M. J. del Jesus, L. Sanchez, F. Herrera // International Journal of Computational Intelligence Systems. – 2017. – No. 10. – P. 1238-1249.

выявил различий между классификаторами, построенными с помощью предлагаемой методики, и нечеткими классификаторами FARC-HD. Кроме этого, различий в точности не выявлено и с классификаторами на основе деревьев решений, построенных с помощью алгоритма CART.

Таблица 6 – Параметры альтернативных интерпретируемых моделей

Классификатор	Название параметра	Значение
FARC-HD	Количество лингвистических терминов на переменную	3
	Минимальный коэффициент поддержки (support)	0,05
	Максимальный коэффициент уверенности (confidence)	0,8
	Максимальное количество терминов в правиле	3
	Максимальное число итераций	15000
	Размер популяции	100
	Параметр альфа ( $\alpha$ )	0,15
CART	Максимальное количество узлов в дереве	[1, к-во образцов – 1]
	Минимальное количество образцов в листовых узлах	[1, к-во образцов / 2]
	Максимальная глубина дерева	[1, макс. к-во узлов]

Таблица 7 – Параметры метода разделения и алгоритмов оптимизации в методике построения нечетких классификаторов

Тип параметра	Название параметра	Значение параметра
Общие параметры	Отношение количества образцов обучающей и валидационной выборок для разделения данных	3:1
	Количество лингвистических терминов на переменную $h$	для всех переменных 3
	Максимальное количество терминов в правиле	3
	Диапазон изменений бокового смещения $\alpha$ и смещения охвата $\beta$	[-0,3 0,3]
Параметры дискретного алгоритма PDT	Размер популяции	30
	Число итераций	1000
	Функция трансформации $T$	Линейная $T_L$
	Вероятность мутации $p$	0,05
Параметры алгоритма MICS	Размер популяции	100
	Число итераций	5000
	Количество правил	Кол-во классов $\times$ 7
	Вероятность удаления гнезда $p_a$	0,05
	Коэффициент прыжка полетов Леви $\gamma$	Равномерно уменьшался с 0,4 до 0,05
Параметры алгоритма градиентного спуска	Минимальная длина шага $e$	$1 \cdot 10^{-8}$
	Начальное значение шага $h$	0,1
	Диапазон изменений бокового смещения $\alpha$ и смещения охвата $\beta$	[-0,3 0,3]

Статистическое сравнение по критерию интерпретируемости представлено в таблице 9. Применялся непараметрический тест Уилкоксона с уровнем значимости  $\alpha = 0,05$ . Количество правил в классификаторах, построенных предлагаемой

методикой, оказалось значительно меньше по сравнению с альтернативами. В среднем из оказалось меньше на 39,2% по сравнению с FARC-HD и на 81,9% по сравнению с деревьями решений CART. Количество используемых признаков по сравнению с FARC-HD оказалось значительно меньше в среднем на 8%. По сравнению с деревьями решений CART количество используемых признаков оказалось значительно больше в случае агрегацией правил функцией максимума и неразлично в случае агрегации правил функцией суммы. Количество условий в правиле оказалось неразличимым по сравнению с классификаторами FARC-HD, а по сравнению с деревьями решений CART получилось значительно меньше в среднем на 54,5%. Общее количество нечетких терминов в базе правил оказалось значительно меньше по сравнению с FARC-HD в среднем на 49,8%.

Таблица 8 – Статистическое сравнение точности классификации

Агрегация правил	Альтернативный классификатор	Сумма рангов		p-value	Гипотеза $H_0$ ( $\alpha=0,05$ )
		+	-		
Максимум	FARC-HD	331	372	0,7566	Принимается
	CART	334	406	0,6031	Принимается
Сумма	FARC-HD	368,5	334,5	0,7949	Принимается
	CART	375	366	0,9442	Принимается

Таблица 9 – Статистическое сравнение показателей интерпретируемости

Агрегация правил	Альтернативный классификатор	Показатель	Сумма рангов		p-value	Гипотеза $H_0$ ( $\alpha=0,05$ )
			+	-		
Максимум	FARC-HD	#R	78	625	<0,001	Отвергается
		#T	55	648	<0,001	Отвергается
		#F	132	463	0,0047	Отвергается
		#D	269	438	0,1936	Принимается
	CART	#R	82	659	<0,001	Отвергается
		#F	491	138	0,0063	Отвергается
#D		24	717	<0,001	Отвергается	
Сумма	FARC-HD	#R	49	654	<0,001	Отвергается
		#T	19	684	<0,001	Отвергается
		#F	86	475	<0,001	Отвергается
		#D	252,5	449,5	0,2077	Принимается
	CART	#R	30,5	710,5	<0,001	Отвергается
		#F	399,5	195,5	0,0819	Принимается
#D		24	717	<0,001	Отвергается	

*Интерпретируемость нечетких классификаторов.* База правил нечетких классификаторов является источником знаний и позволяет понять, каким образом класс образца данных определяется значениями его признаков. На рисунке 13 показано графическое представление базы правил классификаторов, построенных для набора данных Wdbc. Набор данных содержит характеристики ядер клеток опухоли молочной железы, определенных по оцифрованному изображению тонкоигольной аспирационной биопсии. Задача классификации заключается в том, чтобы определить является ли обнаруженная опухоль доброкачественной или

злокачественной. Набор данных содержит 30 признаков, 569 образцов и 2 класса: М – опухоль злокачественная, В – опухоль доброкачественная.

Классификаторы получены с помощью предлагаемой методики в двух запусках построения и обладают одинаковой точностью  $acc=96,49\%$ . Следующие показатели интерпретируемости имеют одинаковое значение:  $\#R=4$ ,  $\#T=8$ ,  $\#D=2$ . Число признаков оказалось разным. На рисунке 13,*а*  $\#F=7$ , а на 13,*б*  $\#F=8$ . Следует отметить, что в исходном наборе 30 признаков. В строках на рисунке представлены правила  $R_1, \dots, R_4$ , а столбцах – признаки. Последний столбец описывает класс правила. На пересечении правила и признака отображаются функции принадлежности лингвистических терминов «Малое», «Среднее», «Большое». Выбранный в правиле термин выделен заливкой. Если термины не отображаются, то в данном правиле соответствующий признак не используется. База правил нечеткого классификатора может быть представлена на естественном языке с учетом лингвистических терминов и названий признаков. Для рисунка 13,*а* она выглядит следующим образом.

$R_1$ : ЕСЛИ периметр 1-го ядра средний И количество вогнутых частей контура 2-го ядра среднее И текстура 3-го ядра средняя ТО опухоль злокачественная.

$R_2$ : ЕСЛИ компактность 1-го ядра высокая И компактность 2-го ядра низкая ТО опухоль злокачественная.

$R_3$ : ЕСЛИ радиус 3-го ядра маленький ТО опухоль доброкачественная.

$R_4$ : ЕСЛИ количество вогнутых частей контура 1-го ядра среднее И текстура 3-го ядра средняя ТО опухоль злокачественная.

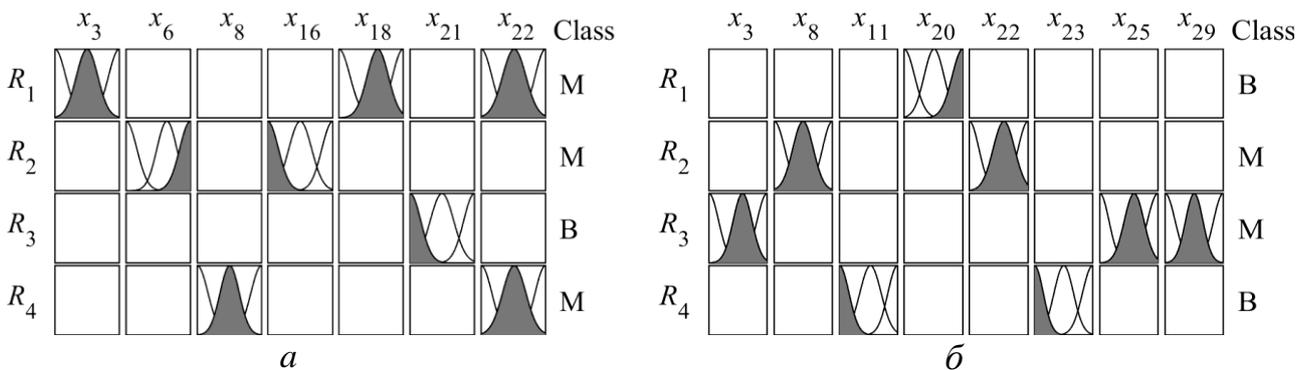


Рисунок 13 – Графическое представление базы правил нечетких классификаторов, построенных для набора данных Wdbc

Для объяснения полученного результата при классификации образца данных нечетким классификатором нужно выделить правило, имеющее максимальную степень соответствия образцу. Степень соответствия определяется операцией конъюнкции в посылке правила. Класс выделенного правила является результатом классификации образца.

На рисунке 14 показана иллюстрация к объяснению результата для классификаторов с правилами рисунка 13. Один и тот же образец обработан классификаторами, представленными на рисунках 13,*а* и 13,*б*. Функция принадлежности в правиле имеет заливку, соответствующую степени принадлежности признака образца данных нечеткому множеству

лингвистического термина. В столбце с информацией о классе правила добавлено значение степени соответствия образца правилу, а в последнем столбце (Degree) приведено графическое изображение этого значения в виде столбчатой диаграммы. Степень соответствия принимает значение из диапазона  $[0, 1]$ . Чтобы объяснить решение о полученном классе образца, нужно показать на какое правило опиралось это решение, а это определяется максимальным значением степени соответствия.

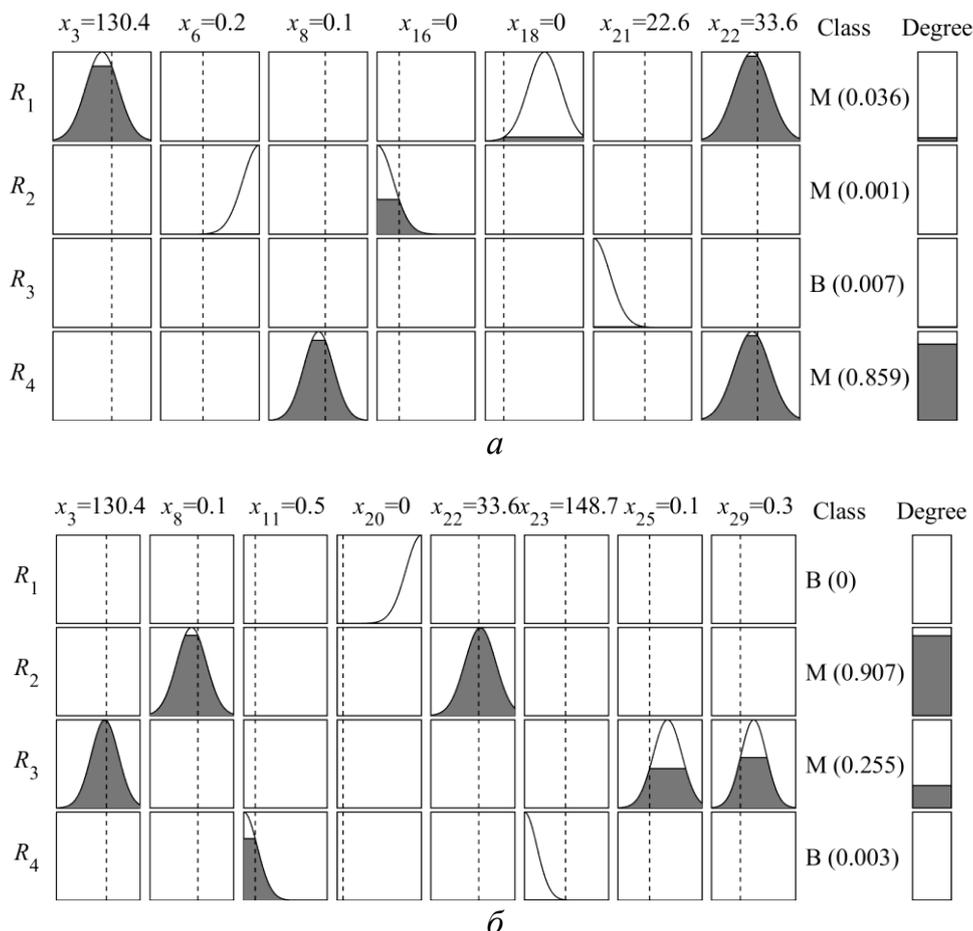


Рисунок 14 – Иллюстрация к объяснению результата принятого решения нечетким классификатором

В четвертом разделе представлено использование результатов диссертационной работы для решения прикладных задач. Предложенная методика построения интерпретируемых нечетких классификаторов применена для создания классификатора и программных средств прогнозирования эффективности реабилитации пациентов после перенесенной коронавирусной инфекции COVID-19. Результаты внедрены в Томском НИИКиФ. Разработанный алгоритм смешанной многокритериальной оптимизации MICS применяется в программных средствах для синтеза согласующих цепей в НИИ МЭС и ООО «Микроэлектронные системы». Разработанный дискретный алгоритм оптимизации внедрен в экспериментальную версию САПР «50ohm Tech Circuit Studio» в ООО «50ом Тех.» и испытан в рамках опытной эксплуатации для синтеза секции ступенчатого СВЧ-аттенюатора.

*Прогнозирование эффективности реабилитации.* Томский НИИКиФ ведет разработки персонализированных технологий комплексной медицинской реабилитации лиц, перенесших коронавирусную инфекцию COVID-19. Одним из результатов этой работы является реабилитационный комплекс, основная цель которого заключается в восстановлении здоровья организма пациента после болезни. Комплекс включает в себя следующие компоненты:

- 1) диета;
- 2) лечебная физическая культура;
- 3) психологическое тестирование и коррекция психологических нарушений;
- 4) классический ручной массаж грудной клетки;
- 5) сухие углекислые ванны;
- 6) спелеотерапия;
- 7) воздействие пульсирующим электростатическим полем на область грудной клетки;
- 8) вазоактивная электростимуляция;
- 9) внутренний прием пробиотического препарата.

Важной задачей в ходе проведения исследования являлась прогнозирование эффективности реабилитации пациента до начала прохождения комплекса, а также определения правил, которые объясняют связь между характеристиками состояния здоровья пациента и достижением эффекта от реабилитации. Реабилитация пациента считается эффективной, если после нее дистанция теста шестиминутной ходьбы (ТШХ) увеличилась на 15% по сравнению с измерениями до реабилитации.

Для решения данной задачи была предложена прогностическая модель на основе нечеткого классификатора. Помимо прогнозного результата классификатор предоставляет базу правил, объясняющую причины найденного решения. Построение классификатора проводилось с помощью разработанной в исследовании методики. Далее представлено описание сбора обучающих данных и построения нечеткого классификатора.

В результате клинических исследований был сформирован набор данных из 58 признаков и 64 образцов данных о пациентах. В набор были включены антропометрические показатели, а также показатели клинических, лабораторных и функциональных методов исследования до начала реабилитации. Выходная метка для задачи классификации была сформирована следующим образом. После вычисления процента улучшения результата ТШХ в метке класса выставлялась значение «1», если этот процент был равен или превышал 15%, и «0» в ином случае.

На основе полученного набора данных с применением методики построения нечетких классификаторов был построен классификатор для прогнозирования эффективности реабилитации. Каждый признак разделялся на три лингвистических термина: «Малое», «Среднее», «Большое». С помощью метода десятикратной перекрестной проверки оценена точность классификации, которая составила 74,67%. База правил классификатора, представленная на рисунке 15, содержит три правила и семь признаков. Последний столбец определяет заключение правила и содержит метку класса: «1» – реабилитация будет эффективной, «0» – реабилитация будет не эффективной.

База правил на естественном языке с учетом лингвистических терминов и названий признаков представлена ниже.

$R_1$ : ЕСЛИ отсутствуют жалобы на ЖКТ И результат ТШХ средний И пиковая скорость выдоха средняя ТО реабилитация будет эффективной

$R_2$ : ЕСЛИ наличие триглицеридов в крови низкое И показатель анализа крови «международное нормализованное отношение» высокий ТО реабилитация будет эффективной

$R_3$ : ЕСЛИ частота сердечных сокращений низкая И количество фибриногена в крови среднее ТО реабилитация будет не эффективной

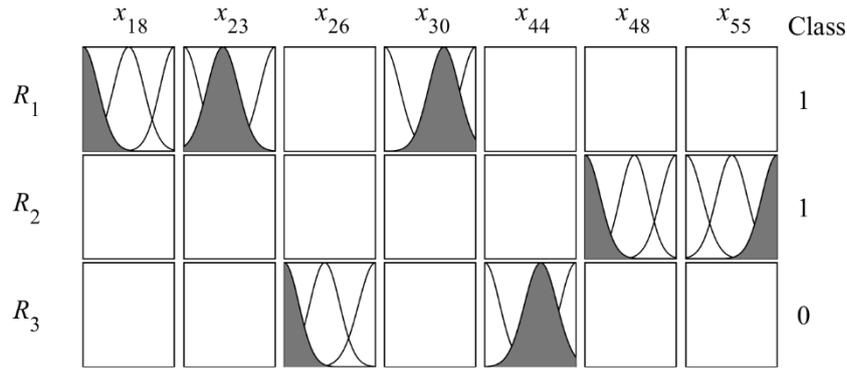


Рисунок 15 – База правил нечеткого классификатора для прогнозирования эффективности реабилитации

*Синтез согласующих цепей.* Согласующие (СЦ) и корректирующие (КЦ) цепи широко применяются в составе радиоэлектронных устройств и систем для согласования входа\выхода устройства с трактом передачи сигнала и обеспечения максимального коэффициента передачи мощности сигнала от генератора в нагрузку в некоторой полосе рабочих частот. При этом сами СЦ и КЦ как правило реализуют на основе реактивных элементов, чтобы они не поглощали мощность передаваемого сигнала.

Синтез широкополосных согласующих цепей является важной задачей при построении радиотехнических и телекоммуникационных систем и устройств. Обычно требования к согласующим цепям являются противоречивыми по показателям качества полученного результата, что усложняет автоматизацию процесса синтеза. Предложен метод структурно-параметрического синтеза широкополосных согласующих цепей на основе алгоритма смешанной многокритериальной оптимизации MICS. Использование смешанной оптимизации позволяет проводить одновременно как структурный, так и параметрический синтез СЦ путем кодирования структуры цепи и ее компонентов с помощью дискретных переменных, а значения их параметров – с помощью непрерывных. Применение многокритериальности дает возможность учитывать несколько целей в процессе синтеза. В работе рассматриваются две цели: с одной стороны необходимо получить цепь, удовлетворяющую заданной форме амплитудно-частотной характеристике (АЧХ), а с другой стороны цепь должна содержать минимально возможное число компонентов, или содержать компоненты, которые обуславливают минимальные затраты на изготовление цепи.

Для того чтобы свести задачу синтеза СЦ к проблеме оптимизации необходимо задать кодирование цепи с помощью переменных вектора решения, определить целевые функции и задать ограничения на значения переменных. Цепь кодируется в виде смешанного вектора, содержащего переменные с целочисленными и вещественными значениями (рисунок 16).

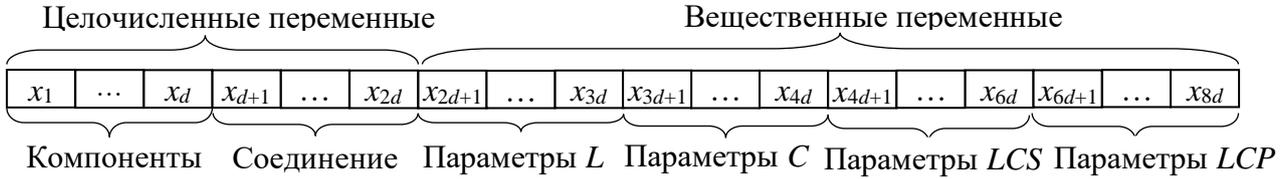


Рисунок 16 – Кодирование цепи вектором решения

Максимальное количество компонентов в цепи ограничено значением  $d$ , которое является параметром и задается до выполнения синтеза. Вектор разделен на целочисленные и вещественные переменные. Целочисленные переменные  $x_1, \dots, x_{2d}$  кодируют структуру цепи. Переменные  $x_1, \dots, x_d$  содержат информацию о типе компонента цепи или его отсутствии. Значение переменной «1» соответствует катушке индуктивности  $L$ , значение «2» – конденсатору  $C$ , значение «3» –  $LC$ -контур с последовательным соединением элементов ( $LCS$ ), значение «4» –  $LC$ -контур с параллельным соединением элементов ( $LCP$ ), значение «0» показывает отсутствие элемента, привязанного к данной переменной. Переменные  $x_{d+1}, \dots, x_{2d}$  кодируют тип соединения соответствующего компонента, значение «1» показывает последовательное соединение, а значение «2» – параллельное. Переменные  $x_{2d+1}, \dots, x_{8d}$  содержат значения параметров компонентов, соответствующих переменным  $x_1, \dots, x_d$ . Для катушек индуктивности это переменные  $x_{2d+1}, \dots, x_{3d}$ ; для конденсаторов –  $x_{3d+1}, \dots, x_{4d}$ ; для  $LCS$  контуров –  $x_{4d+1}, \dots, x_{6d}$ ; для  $LCP$  контуров –  $x_{6d+1}, \dots, x_{8d}$ . Если переменная  $x_i$ , ( $i = 1, \dots, d$ ), кодирует катушку, то ее индуктивность находится в переменной  $x_{2d+i}$ . Если кодирует конденсатор, то его емкость содержится в переменной  $x_{3d+i}$ . Если переменная кодирует  $LCS$ -контур, то индуктивность катушки находится в  $x_{4d+i}$ , а емкость конденсатора в  $x_{5d+i}$ . В случае  $LCP$ -контюра индуктивность содержится в  $x_{6d+i}$ , а емкость в  $x_{7d+i}$ . Пространство поиска (число переменных в векторе решения) ограничено значением  $8d$ .

Таким образом, синтез согласующих цепей сводится к следующей задаче смешанной многокритериальной оптимизации:

$$\left\{ \begin{array}{l} F_1(\mathbf{X}) \rightarrow \min \\ F_2(\mathbf{X}) \rightarrow \min \\ x_i \in \{0, 1, 2, 3, 4\}, i = 1, \dots, d \\ x_i \in \{1, 2\}, i = d + 1, \dots, 2d \\ x_i \in [L_{\min}, L_{\max}], i = 2d + 1, \dots, 3d, 4d + 1, \dots, 5d, 6d + 1, \dots, 7d \\ x_i \in [C_{\min}, C_{\max}], i = 3d + 1, \dots, 4d, 5d + 1, \dots, 6d, 7d + 1, \dots, 8d \end{array} \right. ,$$

где  $F_1$  – максимальное отклонение коэффициента передачи от заданного значения в диапазоне частот работы цепи;  $F_2$  – количество компонентов цепи;  $L_{\min}$  и  $L_{\max}$  – минимальное и максимальное значения индуктивности для катушек;  $C_{\min}$  и  $C_{\max}$  – минимальное и максимальное значения емкости для конденсаторов. Данная задача оптимизации решается алгоритмом смешанной многокритериальной оптимизации MICS.

Тестирование разработанного метода и реализованной на его основе программы на типовых задачах широкополосного согласования показало его работоспособность и эффективность, найденные решения не уступают результатам, которые были получены на основе альтернативных подходов, а в некоторых случаях и превосходят их.

В отличие от генетического алгоритма, реализованного в программе GeneSyn<sup>11</sup>, предлагаемый метод позволяет за один запуск получить набор возможных решений (структур СЦ) с разным количеством элементов близких к оптимальным. В программе GeneSyn для этого потребуется выполнить несколько стартов с разными настройками размерности синтезируемой цепи. Визуальный подход<sup>12</sup> тоже позволяет получать решения близкие к оптимальным, так как дает возможность исследовать решаемую задачу за счет ее визуализации, но он является интерактивным, т.е. требует активного участия человека в процессе синтеза.

*Синтез секции ступенчатого аттенюатора.* Организация ООО «50ом Тех.» ведет разработку интеллектуальной системы автоматизированного проектирования «50ohm Tech Circuit Studio». Система позволяет автоматически синтезировать структуры и параметры СВЧ интегральных схем. Разработанный в данном исследовании дискретный алгоритм оптимизации внедрен в экспериментальную версию данной системы и испытан в рамках опытной эксплуатации для синтеза секции ступенчатого СВЧ-аттенюатора.

Использование дискретного алгоритма оптимизации для синтеза предполагает кодирование секции аттенюатора дискретным вектором решений. Значение параметров компонентов является дискретным и выбирается из предложенного варианта. Схема кодирования представлена на рисунке 17. Максимальное количество компонентов имеет значение  $n$  и задается до запуска алгоритма. Каждый компонент устройства кодируется с помощью восьми элементов вектора решений. Элемент вектора с обозначением « $L$ » соответствует катушки индуктивности. Элемент « $C$ » соответствует конденсатору. Элемент « $T$ » соответствует транзистору. Элемент « $R$ » соответствует резистору. Элемент « $ЛП$ » соответствует линии передачи. Элемент « $CO$ » соответствует сквозному отверстию. Элемент « $ТС$ » соответствует типу соединения компонента. Элемент « $ТЭ$ » соответствуют типу выбранного компонента.

---

<sup>11</sup> Дорофеев С.Ю. Синтез согласующих цепей в распределенном и смешанном элементных базисах / С.Ю. Дорофеев, Л.И. Бабак // Современные проблемы радиоэлектроники. – Красноярск: Сибирский федеральный университет. – 2008. – С. 98–101.

<sup>12</sup> Самуилов А.А. Методика «визуального» проектирования цепей на сосредоточенных элементах для широкополосного согласования двух комплексных нагрузок / А.А. Самуилов, М.В. Черкашин, Л.И. Бабак // Доклады ТУСУР. – 2013. – Т. 28, № 2. – С. 30–39.



3. Показана возможность достижения интерпретируемости нечеткими классификаторами и их способность объяснить результат на естественном языке. База правил классификаторов состоит из продукционных правил, содержащих лингвистические термины для оценивания значений признаков классифицируемого объекта. Данные правила описывают связь между значениями признаков объекта и его классом, что позволяет объяснить моделируемые классификатором процесс или явление. Применение теории нечеткой логики позволяет находить численные решения для выводов в понятной человеку лингвистической форме. Объяснение полученного результата основывается на правилах, которые определили найденный класс.

4. На основе аналитического обзора выявлены недостатки нечетких классификаторов, связанные с низким уровнем интерпретируемости в современных методах построения. Нечеткие классификаторы типа Min-Max содержат большое количество правил, которое доходит до тысяч, и трудно интерпретируемые в лингвистические термины функции принадлежности, что фактически делает невозможным перевести данные правила на естественный язык. Генетические нечеткие системы помимо большого количества правил содержат весовые коэффициенты правил, что также усложняет интерпретируемость. Метод трехэтапного построения нечетких классификаторов формирует правила с функциями принадлежности, форма которых может сильно отличаться от формы функций принадлежности при равномерном разбиении пространства признака. Это затрудняет интерпретацию нечетких множеств в лингвистические термины.

5. Предложена методология построения интерпретируемых нечетких классификаторов, основанных на правилах. Методология определяет совокупность методов анализа данных, процессы, в которых применяются данные методы, и их взаимодействие для построения нечетких классификаторов. В методологии используются методы предобработки данных, методы разделения данных, методы смешанной многокритериальной оптимизации, стратегии выбора решений на фронте Парето и методы оптимизации, основанные на производных.

6. Разработан, реализован и исследован алгоритм многокритериальной оптимизации для поиска оптимума в смешанном, дискретно-непрерывном пространстве, основанный на метаэвристике «кукушкин поиск» и генетическом операторе скрещивания. Генерация новых значений дискретных переменных осуществляется с помощью генетического оператора, а значения непрерывных переменных генерируются метаэвристикой. Алгоритм показал высокую эффективность на комплексных оценках сходимости и многообразия.

7. Разработан, реализован и исследован алгоритм оптимизации для поиска решения в дискретном пространстве, основанный на распределениях вероятностей. Распределения вероятностей формируются с помощью весовых коэффициентов решений, которые определяются трансформационными функциями из целевых значений. Алгоритм показал высокую эффективность на оценках сходимости и стабильности.

8. Разработан метод разделения данных на обучающую и валидационную выборки для построения прогностических моделей машинного обучения, с целью сохранения близости полученных выборок к исходным данным. Проблема

разделения данных в методе сводится к задаче бинарной оптимизации. Введен критерий близости, основанный на среднем значении и среднеквадратичном отклонении признаков данных. Применение метода для построения нечетких классификаторов с помощью многокритериального метаэвристического алгоритма показало повышение точности классификации и интерпретируемости моделей по сравнению со случайным разделением и без разделения исходных данных.

9. Адаптирован, реализован и исследован алгоритм градиентного спуска для настройки параметров среднего значения и среднеквадратичного отклонения функций принадлежности гауссова типа в нечетких классификаторах. Для этого классификатор представлен в виде системы разделяющих функций. Для оптимизации используется целевая функция в виде суммы квадратичных отклонений нормированных значений разделяющих функций от ожидаемых значений. Алгоритм продемонстрировал увеличение точности классификаторов, построенных многокритериальным метаэвристическим алгоритмом.

10. Предложена методика построения интерпретируемых нечетких классификаторов, основанная на методологии построения и использующая разработанные алгоритмы оптимизации и метод разделения данных. Для построения множества недоминируемых по критериям точности и интерпретируемости классификаторов применяется алгоритм смешанной многокритериальной оптимизации «кукушкин поиск» с генетическим оператором скрещивания. Для разделения данных на обучающую и валидационную выборки применяется метод разделения данных с дискретным алгоритмом оптимизации на основе распределения вероятностей. Для дообучения классификатора путем настройки параметров функций принадлежности используется адаптированный алгоритм градиентного спуска. Построенные с помощью методики классификаторы продемонстрировали сопоставимую точность классификации и высокий уровень интерпретируемости по сравнению с известными интерпретируемыми моделями, такими как генетические нечеткие системы FARC-ND и деревья решений CART.

11. Проведены вычислительный эксперимент разработанного алгоритма смешанной многокритериальной оптимизации и сравнение его эффективности с известным генетическим алгоритмом с недоминируемой сортировкой NSGAII на общепринятых тестах ZDT и DTZL. Выявлено статистически значимое преимущество (на уровне  $\alpha=0,05$ ) разработанного алгоритма на комплексных оценках сходимости и многообразия по сравнению с NSGAII. Значение обратного расстояния поколений оказалось меньше в среднем на 95,47%, а степень доминирования больше в среднем на 79,92%.

12. Проведены вычислительный эксперимент разработанного дискретного алгоритма оптимизации и сравнение его эффективности с известными генетическим алгоритмом и алгоритмом роящихся частиц. Эксперимент проводился на общепринятых тестах по поиску оптимума унимодальных и мультимодальных функций в бинарном пространстве поиска. Статистическое сравнение показало значимое преимущество (на уровне  $\alpha=0,05$ ) предлагаемого алгоритма по критериям сходимости и стабильности. В среднем отклонение от оптимального значения целевой функции уменьшилось в 4,3 раза по сравнению с

генетическим алгоритмом и в 10,1 раза по сравнению с алгоритмом роящихся частиц.

13. Проведен вычислительный эксперимент по настройке параметров функций принадлежности нечетких классификаторов с помощью адаптированного алгоритма градиентного спуска. Классификаторы были предварительно построены разработанным метаэвристическим алгоритмом смешанной многокритериальной оптимизации на 38 общедоступных наборах данных. Результаты эксперимента показали статистически значимое (на уровне  $\alpha=0,05$ ) повышение точности. Максимальное увеличение точности классификации составило 5,1%.

14. Проведен вычислительный эксперимент для оценки эффективности применения разработанного метода разделения данных при построении нечетких классификаторов с помощью алгоритма смешанной многокритериальной оптимизации на 38 общедоступных наборах данных. Статистический тест выявил значимое повышение точности (на уровне  $\alpha=0,05$ ) классификации по сравнению с построением классификаторов со случайным разделением данных и без применения разделения данных. Максимальное увеличение точности составило 6,5%. Также выявлено значимое (на уровне  $\alpha=0,05$ ) повышение интерпретируемости по показателям количества правил, количества признаков и общего количества нечетких терминов в базе правил.

15. Проведен вычислительный эксперимент по построению нечетких классификаторов с помощью предлагаемой методики на 38 общедоступных наборах данных. Проведено статистическое сравнение показателей точности и интерпретируемости с известными интерпретируемыми моделями машинного обучения, такими как генетические нечеткие системы FARC-HD и деревья решений CART. Сравнение показало сопоставимую точность классификации (на уровне  $\alpha=0,05$ ) и выявило статистически значимое преимущество (на уровне  $\alpha=0,05$ ) по критерию интерпретируемости классификаторов, построенных с помощью предлагаемой методики. По сравнению с классификаторами FARC-HD значения таких показателей как количество правил, общее количество нечетких терминов и количество признаков оказались значимо меньше. Количество правил меньше в среднем на 39,2%, общее количество нечетких терминов на 49,8%, количество признаков на 8%. По сравнению с деревьями решений CART значимое уменьшение показали количество правил, в среднем на 81,9%, и количество условий в правиле, в среднем на 54,5%. Результаты сравнения подтверждают высокий уровень интерпретируемости нечетких классификаторов, построенных с помощью предлагаемой методики.

16. С помощью разработанной методики построен нечеткий классификатор для прогнозирования эффективности реабилитации пациентов после перенесенной коронавирусной инфекции COVID-19. Получена база из трех продукционных правил, объясняющая связь между показателями здоровья пациента и эффектом от реабилитации. Из 58 исходных признаков в классификаторе используется 7. На основе классификатора созданы программные средства, осуществляющие прогнозирование эффективности реабилитации с точностью 74,67%. Результаты внедрены в Томском НИИКиФ.

17. Алгоритм смешанной многокритериальной оптимизации «кукушкин поиск» с генетическим оператором скрещивания, разработанный в диссертационной работе, применяется в программных средствах для синтеза цепей согласования. Тестирование на типовых задачах широкополосного согласования показало работоспособность и эффективность синтеза по сравнению с альтернативными методами. В задаче одностороннего согласования полученная цепь показала второй результат из девяти вариантов по показателю минимального значения коэффициента передачи, который от лучшего решения отличается на 0,0015дБ, а от худшего на 0,0559 дБ. В задаче двухстороннего согласования найденная цепь продемонстрировала лучший результат данного показателя из девяти вариантов цепей. В задаче согласования-выравнивания синтезированная цепь показала третий результат из восьми вариантов по показателю максимального отклонения коэффициента передачи от желаемого значения с отклонением 0,011дБ от лучшего варианта и 0,096 дБ от худшего. Результаты внедрены в НИИ МЭС и ООО «Микроэлектронные системы» для проектирования СВЧ усилителей различного назначения.

18. Дискретный алгоритм оптимизации на основе распределения вероятностей с трансформацией целевых значений, разработанный в диссертационной работе, внедрен в экспериментальную версию интеллектуальной САПР «50ohm Tech Circuit Studio» и испытан в рамках опытной эксплуатации для синтеза секции ступенчатого СВЧ аттенюатора. В 56 запусках алгоритма из 100 находится применимое решение с максимальным числом итераций 10000. Среднее время синтеза находится в приемлемых для решения поставленной практической задачи пределах и составляет 3 мин. 40 сек. Результаты внедрены в ООО «50ом Тех.».

Таким образом, цель диссертационной работы, заключающаяся в повышении эффективности обнаружения закономерностей в данных с помощью разработки и применения методологии построения интерпретируемых нечетких классификаторов, основанных на правилах, была достигнута, а все поставленные задачи были выполнены.

Перспективы дальнейших исследований автор видит в разработке методов объяснения для систем искусственного интеллекта, основанных на трудно интерпретируемых моделях «черного ящика», таких как нейронные сети глубокого обучения или ансамбли. Перспективным решением в данной области является построение моделей-двойников на основе нечетких систем, имитирующих прогнозы оригинальных моделей. Такое решение позволит получить базу продукционных правил, объясняющую человеку связь между признаками объекта и целевым значением, а также обосновать прогнозируемый результат.

## Основные публикации по материалам диссертации

### *Статьи в журналах из перечня ВАК*

1. Сарин К.С. Методика построения интерпретируемых нечетких классификаторов для систем объяснимого искусственного интеллекта / К.С. Сарин // Доклады ТУСУР. – 2025. – Т. 28, № 2. – С. 73–87.
2. Сарин К.С. Адаптированный алгоритм градиентного спуска для настройки параметров нечеткого классификатора / К.С. Сарин // Информационные и математические технологии в науке и управлении. – 2025. – № 2(38). – С. 18–31.
3. Сарин К.С. Дискретный алгоритм оптимизации на основе распределения вероятностей с трансформацией целевых значений / К.С. Сарин // Программирование. – 2024. – № 6. – С. 35–47.
4. Сарин К.С. Метод разделения данных для построения прогностических моделей машинного обучения / К.С. Сарин // Доклады ТУСУР. – 2024. – Т. 27, № 4. – С. 88–96.
5. Сарин К.С. Гибридный алгоритм смешанной многокритериальной оптимизации «кукушкин поиск» с генетическим оператором скрещивания / К.С. Сарин // Искусственный интеллект и принятие решений. – 2024. – № 2. – С. 87–105.
6. Сарин К.С. Нечеткий классификатор инкрементного обучения типа Min-Max для решения задач кибербезопасности / К.С. Сарин, Р.Е. Коломников, М.О. Светлаков, И.А. Ходашинский // Научно-техническая информация. Серия 2. Информационные процессы и системы. – 2024. – № 9. – С. 11–21.
7. Сарин К.С. Нечеткий классификатор типа Min-Max: обзор / К.С. Сарин // Доклады ТУСУР. – 2023. – Т. 26, № 1. – С. 65–75.
8. Нечеткие классификаторы для диагностики болезни Паркинсона на основе статических рукописных данных / И.А. Ходашинский, Ю.А. Шурыгин, К.С. Сарин, М.Б. Бардамова, А.О. Слёзкин, М.О. Светлаков, Н.П. Корышев // Автометрия. – 2023. – Т. 59, № 3. – С. 72–85.
9. Sarin K. Extracting Knowledge from Images of Meanders and Spirals in the Diagnosis of Patients with Parkinson's Disease / K. Sarin, I. Hodashinsky, M. Svetlakov // Pattern Recognition and Image Analysis. Advances in Mathematical Theory and Applications. – 2022. – Vol. 32, No. 3. – P. 658–664.
10. Сарин К.С. Метод баггинга и отбор признаков в построении нечетких классификаторов для распознавания рукописной подписи / К.С. Сарин, И.А. Ходашинский // Компьютерная оптика. – 2019. – Т. 43, № 5. – С. 833–845.
11. Ходашинский И.А. Отбор классифицирующих признаков с помощью популяционного случайного поиска с памятью / И.А. Ходашинский, К.С. Сарин // Автоматика и телемеханика. – 2019. – № 2. – С. 161–172.
12. Ходашинский И.А. Отбор классифицирующих признаков: сравнительный анализ бинарных метаэвристик и популяционного алгоритма с адаптивной памятью / И.А. Ходашинский, К.С. Сарин // Программирование. – 2019. – № 5. – С. 3–9.

13. Сарин К.С. Метод Чиу для отбора информативных признаков нечетких классификаторов / К.С. Сарин, И.А. Ходашинский // Информатика и системы управления. – 2017. – Т. 53, № 3. – С. 84–95.

14. Ходашинский И.А. Алгоритмы «стадо криля» и кусочно-линейной инициализации для построения систем типа Такаги-Сугено / И.А. Ходашинский, К.С. Сарин, И.В. Филимоненко // Автометрия. – 2017. – Т. 53, № 4. – С. 84–94.

*Работы, опубликованные по теме диссертации и индексированные в базах научных публикаций SCOPUS или Web of Science*

15. Fuzzy Min-Max Classifier in Cybersecurity Applications / K.S. Sarin, R.E. Kolomnikov, M.O. Svetlakov, I.A. Hodashinsky // Automatic Documentation and Mathematical Linguistics. – 2024. – Vol. 58, No. 5. – P. 299–309.

16. Sarin K. S. Discrete Optimization Algorithm Based on Probability Distribution with Transformation of Target Values / K.S. Sarin // Programming and Computer Software. – 2024. – Vol. 50, No. 6. – P. 445–456.

17. A three-stage fuzzy classifier method for Parkinson’s disease diagnosis using dynamic handwriting analysis / K. Sarin, M. Bardamova, M. Svetlakov, N. Koryshev [et al.] // Decision Analytics Journal. – 2023. – Vol. 5. – P. 100274.

18. Binary PSO Variants for Feature Selection in Handwritten Signature Authentication / E. Hancer, M. Bardamova, I. Hodashinsky, K. Sarin, A. Slezkin, M. Svetlakov // Informatica. – 2022. – Vol. 33, No. 3. – P. 523–543.

19. A wrapper metaheuristic framework for handwritten signature verification / E. Hancer, I. Hodashinsky, K. Sarin, A. Slezkin // Soft Computing – A Fusion of Foundations, Methodologies and Applications. – 2021. – Vol. 25, No. 13. – P. 8665–8681.

20. Sarin K. Linear regression to determine the cluster radius for fuzzy rule base generation / K. Sarin, I. Hodashinsky, I. Filimonenko // 2019 International Siberian Conference on Control and Communications, SIBCON 2019 – Proceedings, Tomsk. – Tomsk. – 2019. – P. 1–4.

21. Hodashinsky I. Efficient feature selection algorithm based on population random search with adaptive memory strategies / I. Hodashinsky, K. Sarin, A. Slezkin // Advances in Intelligent Systems and Computing. – 2019. – Vol. 874. – P. 321–330.

22. Feature selection based on swallow swarm optimization for fuzzy classification / I. Hodashinsky, K. Sarin, A. Shelupanov, A. Slezkin // Symmetry. – 2019. – Vol. 11, No. 11. – P. 1423.

23. Sarin K. Feature selection and identification of fuzzy classifiers based on the cuckoo search algorithm / K. Sarin, I. Hodashinsky, A. Slezkin // Communications in Computer and Information Science. – 2018. – Vol. 934. – P. 22–34.

24. Sarin K.S. Identification of fuzzy classifiers based on the mountain clustering and cuckoo search algorithms / K.S. Sarin, I.A. Hodashinsky // 2017 International Siberian Conference on Control and Communications, SIBCON 2017 – Proceedings, Astana, 2017. – P. 1–6.

Заказ № . Тираж 100 экз.

Томский государственный университет  
систем управления и радиоэлектроники

634050, г. Томск, пр. Ленина, 40.

Тел. (3822) 53-30-18.