

На правах рукописи

Мухин Артем Владимирович

**ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ДЛЯ ХРАНЕНИЯ, ВИЗУАЛИЗАЦИИ И
ОБРАБОТКИ ГИПЕРСПЕКТРАЛЬНЫХ ДАННЫХ**

2.3.5. Математическое и программное обеспечение вычислительных систем,
комплексов и компьютерных сетей

АВТОРЕФЕРАТ
диссертации на соискание ученой степени
кандидата технических наук

Самара – 2026

Работа выполнена на кафедре технической кибернетики федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева».

Научный руководитель:

Куприянов Александр Викторович, доктор технических наук, доцент, федеральное государственное автономное образовательное учреждение высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева», заведующий кафедрой технической кибернетики.

Официальные оппоненты:

Кузнецов Павел Константинович, доктор технических наук, профессор, федеральное государственное бюджетное образовательное учреждение высшего образования «Самарский государственный технический университет», профессор кафедры «Электромеханики и автомобильного электрооборудования».

Макаренков Александр Алексеевич, кандидат технических наук, доцент, федеральное государственное бюджетное образовательное учреждение высшего образования «Рязанский государственный радиотехнический университет имени В.Ф. Уткина», ведущий научный сотрудник НИИ обработки аэрокосмических изображений (НИИ «Фотон»).

Ведущая организация:

Федеральное государственное бюджетное образовательное учреждение высшего образования «**Ульяновский государственный технический университет**», г. Ульяновск.

Защита состоится «16» декабря 2026 г. в 10 часов 00 минут на заседании диссертационного совета 24.2.379.09, созданного на базе ФГАОУ ВО «Самарский национальный исследовательский университет имени академика С.П. Королева», по адресу: 443086, Россия, г. Самара, ул. Московское шоссе, д. 34.

С диссертацией можно ознакомиться в библиотеке и на сайте ФГАОУ ВО «Самарский национальный исследовательский университет имени академика С.П. Королева»: https://ssau.ru/resources/dis_protection/mukhin/.

Автореферат разослан «_____» _____ 2026 г.

Ученый секретарь диссертационного
совета 24.2.379.09,
доктор технических наук, доцент

С.В. Востокин

Общая характеристика работы

Актуальность. Гиперспектральные изображения являются одним из наиболее информативных источников данных для анализа объектов и процессов, не выявляемых средствами классической RGB-съемки. Благодаря высокому спектральному разрешению они находят применение в дистанционном зондировании Земли, сельском и лесном хозяйстве, экологии, медицине, геологии, промышленном контроле качества и других прикладных областях. При этом эффективное использование гиперспектральных данных затрудняется их большим объемом, сложной пространственно-спектральной структурой, зависимостью результатов съемки от внешних факторов, а также недостатком открытых размеченных наборов данных для разработки и оценки алгоритмов машинного обучения.

Существующие программные средства для работы с гиперспектральными изображениями, как правило, ориентированы на узкие прикладные сценарии, требуют установки на локальное рабочее место, обладают лицензионными и вычислительными ограничениями и не обеспечивают единого подхода к хранению, визуализации и обработке данных. Существенной проблемой остается недостаточная автоматизация анализа: пользователь вынужден самостоятельно выбирать алгоритмы, задавать параметры обработки, выполнять подготовку данных и интерпретировать промежуточные результаты, что ограничивает применение гиперспектрального анализа специалистами без углубленной подготовки в области машинного обучения и обработки изображений.

Значимой также является задача функциональной расширяемости программных комплексов. Быстрое развитие методов классификации, сегментации, кластеризации, снижения размерности и формирования спектральных индексов требует возможности подключения новых алгоритмов, пользовательских моделей машинного обучения без существенной модификации системы.

В связи с этим актуальной является разработка интеллектуальной системы для хранения, визуализации и обработки гиперспектральных изображений, обеспечивающей централизованную работу с данными, интерактивную визуализацию, автоматизированное выполнение обработки, формирование информативных спектральных признаков, предварительную разметку данных и интеграцию пользовательских алгоритмов и моделей машинного обучения в единой программной среде. Решение данной задачи позволит повысить доступность средств анализа гиперспектральных изображений, снизить требования к квалификации пользователя и повысить эффективность применения гиперспектральных данных в научных и прикладных задачах.

Степень разработанности темы. Развитию аппаратных средств регистрации гиперспектральных данных сопутствовало развитие методов и алгоритмов их обработки, анализа и интерпретации. Вопросы анализа гиперспектральных изображений получили широкое развитие в работах российских и зарубежных исследователей. Существенный вклад в развитие данного научного направления внесли В.А. Зеленцов, Н.Л. Казанский, В.В. Козодеров, Е.А. Лупян, В.В. Мясников, А.В. Никоноров, Н.А. Обухова, И.А. Пестунов, В.Э. Пожар, О.И. Потатуркин, В.П. Пяткин, В.П. Саворский, В.В. Сергеев, В.А. Сойфер, В.Е. Турлапов, В.А. Фурсов, Б.В. Шилин и др. Существенный вклад в исследование вопросов формирования, комплексирования, сегментации и обработки гиперспектральных изображений внесли В.В. Еремеев, А.А. Макаренков, А.Э. Москвитин, А.А. Юдаков, Н.А. Егошкин, С.В. Антонушкина, Г.Н. Мятлов и др. Среди зарубежных ученых, работы которых

оказали значительное влияние на развитие методов анализа гиперспектральных изображений, следует отметить J.A. Benediktsson, J.M. Bioucas-Dias, J.W. Boardman, L. Bruzzone, G. Camps-Valls, C.-I. Chang, J. Chanussot, M. Fauvel, P. Gamba, D. Landgrebe, J.F. Mustard, J.M.P. Nascimento, A. Plaza и др.

Несмотря на значительную степень проработанности методов анализа гиперспектральных изображений, сохраняется потребность в разработке интеллектуальных систем, обеспечивающих не только выполнение отдельных алгоритмов обработки, но и объединение в единой программной среде инструментов решения задач хранения, визуализации, автоматизированной обработки, предварительной разметки данных, анализа и интеграции пользовательских алгоритмов.

Целью диссертационной работы является разработка интеллектуальной системы для автоматизации обработки гиперспектральных данных, обеспечивающей формирование информативных спектральных индексов, предварительную разметку данных, хранение, визуализацию, анализ и возможность интеграции пользовательских алгоритмов в единой программной среде.

В соответствии с поставленной целью сформулированы следующие **основные задачи диссертации**:

- 1) сформировать систему значимых требований к математическому и программному обеспечению автоматизированной обработки гиперспектральных изображений на основе обзора существующих методов, алгоритмов и систем;
- 2) разработать архитектуру и функционально расширяемую интеллектуальную систему для хранения, визуализации и обработки гиперспектральных изображений, обеспечивающую интеграцию пользовательских алгоритмов и моделей машинного обучения;
- 3) разработать методы и алгоритмы автоматизированной обработки гиперспектральных изображений, обеспечивающие построение информативных спектральных индексов и предварительную разметку данных.

Научная новизна работы состоит в следующих полученных результатах:

- 1) разработана архитектура интеллектуальной системы обработки гиперспектральных данных, отличающаяся выделением независимых компонентов управления исходными гиперспектральными данными, результатами анализа и визуализации, постановки вычислительных задач и выполнения алгоритмов, что обеспечивает горизонтальное масштабирование компонентов системы и её функциональное расширение за счёт интеграции пользовательских алгоритмов и моделей машинного обучения;
- 2) разработана интеллектуальная система для хранения, визуализации и обработки гиперспектральных изображений, отличающаяся объединением в единой программной среде функций централизованного управления гиперспектральными данными, интерактивной визуализации, автоматизированной обработки, интеграции пользовательских алгоритмов и моделей машинного обучения, а также выполнения вычислительных задач с использованием распределённых вычислительных ресурсов;
- 3) впервые разработан алгоритм формирования информативного спектрального индекса, отличающийся автоматическим отбором пары спектральных полос для выделения целевых объектов, заданных в рамках пользовательской задачи,

что позволяет формировать интерпретируемый спектральный признак без ручного выбора спектральных каналов и упрощает применение алгоритма на различных наборах гиперспектральных данных;

- 4) разработан метод автоматической разметки гиперспектральных изображений, отличающийся совместным применением нейросетевой сегментации и информативных спектральных индексов для уточнения предварительных меток, что позволяет уменьшить потребность в ручном формировании эталонной разметки и упростить создание обучающих выборок для последующего применения нейросетевых алгоритмов.

Теоретическая значимость работы заключается в развитии методов автоматизированной обработки гиперспектральных изображений за счёт формализации задач построения информативных спектральных индексов для бинарной и многоклассовой сегментации, разработки алгоритмов INDI и MINDI для автоматического формирования интерпретируемых спектральных признаков, а также разработки алгоритма A-MINDI для формирования предварительной разметки данных при отсутствии исходной экспертной разметки.

Практическая значимость работы заключается в возможности применения разработанных алгоритмов и интеллектуальной системы для хранения, визуализации и автоматизации обработки гиперспектральных изображений, а также для формирования информативных индексов, обеспечивающих выделение целевых областей, определяемых условиями прикладной задачи. Разработанные решения позволяют снизить трудоемкость анализа гиперспектральных данных, уменьшить зависимость от ручного выбора спектральных полос и параметров обработки, а также обеспечить расширение функциональных возможностей системы за счет интеграции пользовательских алгоритмов и моделей машинного обучения.

Результаты диссертации использованы при выполнении ряда госбюджетных работ:

- 1) государственное задание Минобрнауки России № 0777-2020-0017 «Разработка теоретических основ, методического и программного обеспечения для решения задач оперативного мониторинга Земли на основе интеллектуальной обработки и тематической классификации гиперспектральных данных с использованием линейки малых космических аппаратов на базе платформы «АИСТ»;
- 2) государственное задание Минобрнауки России № FSSS-2021-0016 «Дизайн высокоточных спектральных фильтров и интегрированных на чипе спектрометров на основе структур нанофотоники для мониторинга характеристик окружающей среды»;
- 3) государственное задание Минобрнауки России № FSSS-2023-0006 «Теоретические основы и программное обеспечение систем интеллектуального анализа оптических изображений и видеопотоков для экспериментального исследования характеристик аналоговых фотонных сопроцессоров с применением графических ускорителей»;
- 4) научное исследование и разработка в рамках реализации Программы развития передовой инженерной аэрокосмической школы (ПИАШ), проект «Технология интеллектуального анализа данных ДЗЗ на основе цифровой платформы и создание лабораторного макета полнокадрового гиперспектрального комплекса»;

- 5) проект №20-51-05008 РФФИ (Арм_а) построение вычислительно эффективных процедур для формирования набора информативных признаков согласованных с текстурными свойствами изображений.

Методология и методы исследования. В диссертационной работе используются методы цифровой обработки изображений, спектрального анализа, машинного обучения, системного анализа и проектирования распределенных программных систем. В работе использованы методы анализа научно-технической литературы, формализации задач формирования информативных спектральных признаков, сегментации, кластеризации, классификации, оценки информативности спектральных каналов и отделимости классов. При разработке интеллектуальной системы применялись методы объектно-ориентированного проектирования, асинхронной обработки вычислительных задач, контейнеризации и организации взаимодействия программных компонентов. Достоверность результатов подтверждалась экспериментальными исследованиями с использованием общепринятых метрик и открытых наборов данных.

Соответствие паспорту специальности. Диссертация соответствует паспорту научной специальности 2.3.5. Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей (технические науки):

4. Интеллектуальные системы машинного обучения, управления базами данных и знаний, инструментальные средства разработки цифровых продуктов.

7. Модели, методы, архитектуры, алгоритмы, форматы, протоколы и программные средства человеко-машинных интерфейсов, компьютерной графики, визуализации, обработки изображений и видеоданных, систем виртуальной реальности, многомодального взаимодействия в социкиберфизических системах.

Основные положения, выносимые на защиту:

- 1) архитектура интеллектуальной системы обработки гиперспектральных изображений, обеспечивающая разделение функций управления данными, визуализации и обработки, горизонтальное масштабирование компонентов и функциональное расширение системы за счёт интеграции пользовательских алгоритмов и моделей машинного обучения;
- 2) интеллектуальная система для хранения, визуализации и обработки гиперспектральных изображений, реализующая централизованную работу с данными, интерактивную визуализацию, асинхронный и автоматизированный анализ гиперспектральных изображений, а также интеграцию пользовательских алгоритмов и моделей машинного обучения;
- 3) алгоритм формирования ансамбля информативных индексов, обеспечивающий выбор множества пар спектральных каналов и построение набора нормализованных разностных индексов для классификации заданных классов объектов на гиперспектральном изображении, определяемых условиями пользовательской задачи;
- 4) метод автоматического формирования ансамбля информативных индексов, обеспечивающий построение ансамбля индексов без исходной экспертной разметки и применимый как для автоматизированного анализа гиперспектральных изображений, так и для формирования разметки при последующем обучении моделей машинного обучения.

Достоверность полученных результатов достигается за счёт применения объективных и общепринятых метрик оценки качества анализа

гиперспектральных изображений, воспроизводимости вычислительных экспериментов на различных наборах данных, сравнений с эталонными алгоритмами, а также подтверждения результатов в авторитетных рецензируемых изданиях и на профильных научных конференциях.

Апробация работы. Основные результаты диссертации были представлены на международных научных конференциях: X Международная конференция и молодёжная школа «Информационные технологии и нанотехнологии» (ИТНТ-2024), VIII Международная конференция и молодёжная школа «Информационные технологии и нанотехнологии» (ИТНТ-2022), VII Международная конференция и молодёжная школа «Информационные технологии и нанотехнологии» (ИТНТ-2021); 3-й международный семинар в Американском университете Армении, Колледж науки и техники (23-25 августа, 2022, Армения).

Авторский вклад. Личный вклад автора состоит в самостоятельном выполнении основных этапов диссертационного исследования, включая формулирование и уточнение исследовательских задач, разработку математических и программных средств для решения задач хранения, визуализации и обработки гиперспектральных данных, планирование и проведение экспериментальных исследований, анализ и интерпретацию полученных результатов, апробацию результатов исследования, разработку архитектуры и реализацию интеллектуального программного комплекса. Концепция диссертационной работы и общее направление исследований определялись автором совместно с научным руководителем.

Публикации. По теме диссертационной работы автором опубликовано 8 работ, в т.ч. 2 работы в изданиях, индексируемых в базах данных Scopus и Web of Science (WoS), 3 работы в изданиях из списка ВАК РФ, получено 8 свидетельств о государственной регистрации программы для ЭВМ.

Объем и структура работы. Диссертация состоит из введения, трех глав, заключения, списка литературы из 143 наименований и одного приложения. Работа изложена на 245 страницах, содержит 83 рисунка, 24 таблицы.

Основное содержание работы

Во **введении** обоснована актуальность исследования, сформулированы цель и задачи работы, определены объект и предмет исследования, изложены научная новизна, практическая значимость, положения, выносимые на защиту, сведения об апробации, публикациях и личном вкладе автора.

В **первой главе** рассмотрены теоретические основы анализа гиперспектральных изображений. Дано определение гиперспектральных данных, рассмотрены их основные свойства, особенности пространственно-спектральной структуры и области практического применения. Проведён обзор существующих методов и алгоритмов решения задачи сегментации гиперспектральных данных, рассмотрены особенности их применения и ограничения.

Выполнен сравнительный анализ существующих программных средств и систем обработки гиперспектральных изображений. Для их сопоставления использована система свойств, отражающих полный цикл пользовательского сценария: доступ к системе, загрузку и организацию хранения данных, интерактивную визуализацию, аналитическую обработку и расширение функциональных возможностей. Выделенные свойства сгруппированы по функциональным блокам, характеризующим доступность и способ эксплуатации системы, управление гиперспектральными

данными, средства визуального исследования изображений, набор поддерживаемых методов анализа, а также возможность подключения пользовательских алгоритмов и моделей машинного обучения.

Проведённый обзор показал, что существующие системы, как правило, ориентированы на отдельные этапы работы с гиперспектральными изображениями, обладают ограниченными возможностями централизованного хранения и облачного доступа, а также недостаточно поддерживают функциональное расширение за счёт интеграции пользовательских вычислительных модулей.

В результате первой главы сформирована система значимых требований к математическому и программному обеспечению автоматизированного анализа гиперспектральных изображений. Установлено, что разрабатываемая интеллектуальная система должна обеспечивать облачную модель доступа, независимость от операционной системы и характеристик пользовательского устройства, централизованное хранение гиперспектральных изображений и результатов их обработки, поддержку данных различного происхождения, форматов и размерности, а также средства интерактивной визуализации гиперспектральных данных. Кроме того, интеллектуальная система должна обеспечивать автоматизацию отдельных этапов обработки данных, а также позволять пользователю интегрировать в систему собственные алгоритмы и модели обработки гиперспектральных данных. На основе обзора методов анализа гиперспектральных изображений сформулированы требования к математическому обеспечению интеллектуальной системы. Установлено, что применяемые алгоритмы должны учитывать пространственно-спектральную структуру данных и обеспечивать обработку изображений с различным числом спектральных каналов. Особое внимание уделено возможности работы в условиях ограниченной или отсутствующей экспертной разметки, поддержке бинарной и многоклассовой сегментации, а также формированию интерпретируемых результатов анализа. Дополнительно определены требования к вычислительной эффективности алгоритмов, возможности их векторно-матричной и параллельной реализации, а также интеграции в программную систему через унифицированные интерфейсы.

Во **второй главе** выполнено проектирование архитектуры интеллектуальной системы обработки гиперспектральных изображений и представлена её программная реализация. На основе сформированной системы значимых требований разработана микросервисная архитектура, отличающаяся выделением независимых компонентов управления исходными гиперспектральными данными, результатами анализа и визуализации, постановки вычислительных задач и выполнения алгоритмов. Такое разделение обеспечивает возможность независимой разработки, развёртывания и горизонтального масштабирования отдельных компонентов системы, а также её функционального расширения за счёт интеграции пользовательских алгоритмов и моделей машинного обучения.

В рамках проектирования определены архитектурно значимые, функциональные и нефункциональные требования к интеллектуальной системе. К архитектурно значимым отнесены требования функциональной расширяемости за счёт интеграции пользовательских алгоритмов, горизонтальной масштабируемости компонентов и облачного развёртывания, обеспечивающего доступ к системе без установки специализированного программного обеспечения на пользовательском устройстве. Функциональные требования включают загрузку и централизованное хранение гиперспектральных изображений и метаданных, интерактивную визуализацию,

запуск алгоритмов анализа, хранение результатов обработки, управление пользовательскими алгоритмами и моделями машинного обучения, а также повторное использование ранее полученных результатов. К нефункциональным требованиям отнесены масштабируемость, отказоустойчивость, функциональная расширяемость, облачный доступ, асинхронное выполнение вычислительных задач, удобство использования и снижение требований к характеристикам клиентского устройства.

Для описания разработанной архитектуры использованы контекстная диаграмма, диаграмма контейнеров и диаграммы компонентов, выполненные в соответствии с моделью C4. Разработана логическая модель данных, обеспечивающая хранение гиперспектральных изображений, их метаданных, сведений об алгоритмах, вычислительных задачах и результатах обработки.

Наиболее полное представление разработанной архитектуры даёт диаграмма контейнеров, приведённая на рисунке 1, выполненная в нотации C4. Интеллектуальная система представлена как облачная микросервисная система, доступ к которой осуществляется посредством веб-приложения. Прокси-сервер выполняет маршрутизацию пользовательских запросов к соответствующим компонентам системы. Функции управления исходными гиперспектральными данными, результатами анализа, визуализацией и вычислительными задачами выделены в самостоятельные сервисы, взаимодействующие через формализованные программные интерфейсы.

Для обработки пользовательских запросов применяются HTTP-интерфейсы, а обмен сообщениями при выполнении длительных вычислительных операций организован с использованием брокера RabbitMQ. Асинхронное взаимодействие снижает связанность компонентов и позволяет независимо масштабировать сервисы в зависимости от пользовательской нагрузки. Алгоритмы анализа гиперспектральных изображений выполняются в самостоятельных контейнеризированных вычислительных модулях. Компоненты управления вычислениями обеспечивают регистрацию задач, передачу исходных данных и параметров, контроль выполнения и сохранение полученных результатов. Инфраструктурный уровень включает средства контейнерной оркестрации, мониторинга и автоматизированного развёртывания, обеспечивающие горизонтальное масштабирование, контроль состояния компонентов и управляемое обновление системы.

Таким образом, представленная на рисунке 1 архитектура отражает разделение функций работы с гиперспектральными данными, визуализации и вычислительной обработки, а также механизм интеграции пользовательских алгоритмов и моделей машинного обучения. Новизна предложенного архитектурного решения заключается в предметно-ориентированной организации интеллектуальной системы обработки гиперспектральных изображений, обеспечивающей независимое масштабирование компонентов и функциональное расширение без изменения существующих сервисов хранения, визуализации и управления вычислительными задачами.

При разработке интеллектуальной системы использован технологический стек, сформированный на основе программных средств, библиотек, фреймворков и стандартов, распространяемых по открытым лицензиям. Веб-интерфейс реализован с использованием библиотеки React. Серверные компоненты разработаны на языке Python с применением веб-фреймворка FastAPI.

Для описания, валидации и обмена данными использованы библиотеки ODMantic и Pydantic. Обработка изображений и численных массивов выполняется средствами NumPy и OpenCV. Асинхронное выполнение вычислительных задач реализовано с

использованием Celery, а обмен сообщениями между компонентами системы — на основе протокола AMQP и брокера RabbitMQ.

Контейнеризация компонентов системы выполнена с использованием Docker Engine и Docker Compose. Для развёртывания и сопровождения применены Kubernetes, Helm и FluxCD. Маршрутизация сетевых запросов обеспечивается средствами Traefik, а мониторинг состояния системы – средствами Grafana OSS. Используемый технологический стек обеспечивает воспроизводимость развёртывания, переносимость системы между вычислительными средами и возможность её дальнейшего развития.




Рисунок 1 – Диаграмма контейнеров интеллектуальной системы

Пользовательский интерфейс управления алгоритмами реализован в виде специализированного раздела веб-приложения. В нём отображается перечень зарегистрированных вычислительных модулей и предоставляется форма для интеграции нового алгоритма. Разработчик алгоритма указывает его название, описание, параметры запуска и сведения о контейнерном образе, размещённом во внешнем реестре. Система проверяет переданные данные, регистрирует алгоритм и отображает сведения о нём в перечне доступных вычислительных модулей. После успешной интеграции алгоритм становится доступен пользователю при формировании вычислительной задачи. При возникновении ошибки система сохраняет сведения о причине неудачной интеграции, что позволяет применять разработанный механизм при создании и отладке новых алгоритмов.

Для унификации интеграции пользовательских алгоритмов разработан программный интерфейс *vidis_algorithms_api*. Новый алгоритм реализуется в виде самостоятельного контейнеризированного вычислительного модуля, взаимодействующего с интеллектуальной системой через заданные программные интерфейсы. Разработчик определяет имя алгоритма, структуру входных параметров и функцию обработки спектральных данных. Алгоритму передаются необходимые спектральные слои и пользовательские параметры, а результатом выполнения является вычисленный слой, модель представления либо иной объект анализа, сохраняемый в системе и доступный для последующей визуализации и повторного использования.

Пример реализации пользовательского алгоритма приведён в листинге. Разработчик наследует класс алгоритма от базового класса *Task*, задаёт его имя и реализует метод *task*, содержащий прикладную логику обработки гиперспектрального изображения. Формирование асинхронной вычислительной задачи, получение исходных данных, передача параметров и возврат результата обеспечиваются средствами разработанного программного интерфейса.

```
1. import numpy as np
2. from celery import Celery
3. from vidis_algorithms_api import Task, CeleryTaskLifecycle
4. from vidis_algorithms_api.core import settings
5.
6. class Kmeans(Task):
7.     name = "kmeans"
8.     def task(self, hyperspecter: np.ndarray, **kwargs) -> np.ndarray:
9.         # Пользовательская реализация алгоритма.
10.        # Всё остальное является шаблоном подключения алгоритма
11.        pass
12.
13. celery = Celery(
14.     "algorithms",
15.     backend=settings.CELERY_BACKEND,
16.     broker=settings.CELERY_BROKER)
17.
18. @celery.task(name=Kmeans.name, base=CeleryTaskLifecycle)
19. def your_algorithm(*args, **kwargs):
20.     task = Kmeans()
21.     return task.run(*args, **kwargs)
```

Таким образом, для расширения интеллектуальной системы разработчику необходимо реализовать только содержательную часть алгоритма обработки данных, тогда как взаимодействие с системой, запуск вычислительной задачи, передача входных данных и возврат результата обеспечиваются разработанным программным интерфейсом.

Возможность применения нейросетевых методов для анализа гиперспектральных

изображений исследована в ранее опубликованных работах автора. Разработанная интеллектуальная система поддерживает интеграцию и выполнение нейросетевых моделей в виде независимых вычислительных модулей. Однако применение нейросетевых методов требует подготовки обучающих выборок, выбора архитектуры и настройки гиперпараметров, что не в полной мере соответствует сформулированным требованиям к математическому обеспечению, прежде всего в части минимизации участия пользователя и возможности работы в условиях ограниченной или отсутствующей экспертной разметки. В связи с этим основной акцент в работе сделан на разработке алгоритмов автоматизированного анализа гиперспектральных изображений на основе информативных спектральных индексов.

Для оценки масштаба разработанной системы выполнен анализ структуры исходного кода без учета библиотечных файлов. Система включает 874 файла и 64 191 строку, из которых 54 993 строки относятся к программному коду, 2 543 строки – к комментариям. Полученные значения характеризуют разработанную систему как многокомпонентную программную систему, включающую серверную часть, веб-интерфейс, алгоритмические модули, средства конфигурации, контейнеризации и развертывания.

Экспериментальная оценка расширения интеллектуальной системы за счет добавления алгоритмов показала, что среднее значение метрики Mean Time To Availability по результатам 10 запусков составляет 1,51 с без учета первичной загрузки образа контейнера. При подключении нового алгоритма количество строк кода существующих компонентов системы, требующих изменения (LoC), составило 0, а время простоя системы – 0. Это подтверждает функциональную расширяемость предложенной архитектуры.

Во второй главе проведено экспериментальное исследование характеристик интеллектуальной системы. Продемонстрированы основные пользовательские сценарии: организация хранения гиперспектральных данных, добавление гиперспектральных изображений, визуализация, редактирование метаданных, анализ данных с использованием спектральных индексов, подключение нового алгоритма и его последующее применение. Нагрузочное тестирование подтвердило отсутствие отказов микросервисов в рассмотренных сценариях. При независимом тестировании отдельных компонентов максимальная пропускная способность составила 1410,4 запроса в секунду для микросервиса организации хранения гиперспектральных изображений, 914,6 запроса в секунду для микросервиса взаимодействия с алгоритмами и 142,8 запроса в секунду для микросервиса базовой обработки гиперспектральных изображений. В режиме, имитирующем поведение реальных пользователей, средняя задержка составила 45,81 мс для микросервиса хранения, 40,79 мс для микросервиса взаимодействия с алгоритмами и 315,94 мс для микросервиса базовой обработки; 99-й перцентиль задержки не превысил 700 мс для микросервиса базовой обработки.

В третьей главе демонстрируются разработанные алгоритмы и методы хранения, визуализации и анализа гиперспектральных изображений, составляющие алгоритмическую основу интеллектуальной системы. Основной акцент сделан на автоматизации анализа, снижении требований к квалификации пользователя и возможности применения методов без ручного выбора спектральных каналов, настройки сложных моделей и подготовки больших размеченных наборов данных.

Пусть задано гиперспектральное изображение:

$$X=\{x(u) \mid u \in \Omega\},$$

где $\Omega \subset \mathbb{Z}^2$ – множество пикселей изображения,

$x(u) \in \mathbb{R}^B$ – спектральный вектор пикселя u ,

B – число спектральных каналов.

Тогда всё изображение может рассматриваться как матрица или тензор гиперспектральных данных, а все операции анализа сводятся к операциям над векторами признаков, матрицами наблюдений и матрицами статистик. Такое представление является важным, поскольку обеспечивает вычислительную эффективность разрабатываемых алгоритмов, их естественную векторизацию и возможность параллельной реализации.

Пусть также задано множество целевых классов:

$$C=\{c_1, c_2, \dots, c_K\}.$$

Разметка изображения определяется отображением:

$$Y:\Omega \rightarrow C,$$

которое каждому пикселю ставит в соответствие метку класса.

Под индексом далее понимается функция:

$$I:\mathbb{R}^B \rightarrow \mathbb{R},$$

которая отображает спектральный вектор пикселя в числовую характеристику, предназначенную для различения объектов или классов объектов на гиперспектральном изображении. Применение индекса I к спектральному изображению X задает матрицу значений индекса:

$$Z_I:\Omega \rightarrow \mathbb{R}, \quad Z_I(u)=I(x(u)).$$

Пусть I – множество допустимых индексов. Тогда задача формирования информативного индекса заключается в построении отображения:

$$\Psi_I:(X,Y) \rightarrow I^*, \quad I^* \in I,$$

которое по гиперспектральному изображению и разметке позволяет определить информативный индекс I^* , наиболее подходящий для различения заданных классов объектов.

В третьей главе описывается класс алгоритмов, основанных на разработанной *методике формирования информативного спектрального индекса*. В ее основе лежит идея автоматического поиска комбинации спектральных слоев, образующих спектральный индекс, наиболее пригодный для разделения заданных классов объектов. В отличие от классических индексов, формируемых вручную с учетом физических свойств конкретных объектов, предлагаемый подход позволяет строить индекс автоматически на основе обучающих данных. Это повышает универсальность метода и позволяет применять его к различным наборам данных и прикладным задачам.

На основе предложенной методики разработан *алгоритм формирования информативного нормализованного разностного индекса INDI*. Алгоритм предназначен для решения бинарной задачи классификации пикселей и выполняет автоматический выбор пары спектральных каналов для вычисления нормализованного разностного индекса $I(p,q)=(x(p)-x(q))/(x(p)+x(q))$, $p,q \in \{1, \dots, B\}, p \neq q$. Использование такой формы индекса обеспечивает относительную устойчивость к изменению общей яркости и позволяет получить интерпретируемую числовую характеристику, отражающую различия между двумя классами объектов. Основная задача алгоритма заключается в автоматическом выборе такой пары

спектральных полос, при которой значения индекса для пикселей разных классов оказываются максимально разделенными, а значения внутри каждого класса – наиболее компактными. Для решения этой задачи используется критерий информативности, основанный на соотношении межклассовой S_b и внутриклассовой S_w дисперсий:

$$J(p, q) = \frac{S_b(p, q)}{S_w(p, q) + \epsilon} \rightarrow \max$$

На каждом шаге алгоритм перебирает допустимые пары спектральных каналов, вычисляет для них значения нормализованного разностного индекса по обучающим пикселям двух классов, оценивает разделяющую способность полученного признака и выбирает пару каналов, обеспечивающую наибольшее значение критерия информативности. Результатом работы алгоритма является информативный спектральный индекс, определяемый выбранной парой спектральных каналов и используемый для построения карты значений индекса по всему изображению. Далее такая карта может быть преобразована в бинарную маску целевого класса, использована для сегментации объектов, предварительной разметки данных или как информативный признак в последующих алгоритмах анализа. На рисунке 2 представлена блок-схема, описывающая разработанный алгоритм INDI.




Рисунок 2 – Диаграмма, описывающая разработанный алгоритм INDI

Экспериментальная оценка точности алгоритма на изображении Salinas Valley показала, что алгоритм способен формировать индексы, пригодные для выделения различных классов объектов (16 классов) в постановке «один против остальных». Среднее значение метрики F_2 по всем классам составило 0,65, средняя полнота – 0,81, а средняя точность – 0,48. Показано также, что применение медианной фильтрации и морфологических операций повышает значение F_2 с 0,47 до 0,65, примерно на 40%. При решении задачи разделения классов «Сельдерей» и «Стерня» индекс, сформированный INDI, обеспечил значение $F_2 = 0,79$, тогда как при использовании

традиционного нормализованного разностного вегетационного индекса NDVI, применяемого для оценки состояния растительности, значение F_2 составило 0,73.

Применимость разработанного алгоритма была исследована при решении других задач. Так, при обнаружении нефтяных загрязнений на изображении GM1 из набора Hyperspectral Remote Sensing Oil Spill Benchmark Database получено значение $F_2 = 0,74$, при этом значение точности составило 0,38, полноты 0,98 и $AUC = 0,991$, что свидетельствует о высокой полноте обнаружения целевых областей и выраженной разделяющей способности сформированного индекса. В задаче обнаружения очагов лесных пожаров на мультиспектральном изображении из набора Active Fire Detection in Landsat-8 Imagery получено значение $F_2 = 0,94$, при значениях точности 0,79, полноты 0,99 и $AUC = 0,998$. Полученные результаты подтверждают возможность применения INDI к различным предметным задачам и к изображениям с различным числом спектральных каналов.

Алгоритм MINDI является развитием алгоритма INDI и предназначен для формирования ансамбля информативных нормализованных разностных индексов при решении многоклассовых задач анализа гиперспектральных изображений. В отличие от INDI, который строит один индекс для разделения заданной пары классов, MINDI рассматривает жадную задачу в постановке «один против остальных»: для каждого класса формируется индекс, обеспечивающий его отделение от совокупности всех других классов. При этом построение ансамбля происходит упорядоченно. Порядок формирования индексов определяется оценкой отделимости классов: на каждом этапе выбирается класс, для которого критерий отделимости J_k имеет наибольшее значение:

$$J_k = \text{tr} \left(\left(S_w^{(k)} \right)^{-1} S_b^{(k)} \right).$$

Такой подход позволяет учесть специфику многоклассовой задачи при формировании ансамбля информативных индексов. Формирование итоговой маски классов $\hat{Y}$ осуществляется за счет вычисления оценки принадлежности классу:

$$s_k(u) = \frac{(Z_k(u) - \mu_{-k})^2}{(\sigma_{-k})^2 + \epsilon} - \frac{(Z_k(u) - \mu_k)^2}{(\sigma_k)^2 + \epsilon}.$$

Тогда итоговый класс пикселя определяется по максимальной оценке:

$$\hat{Y}(u) = \underset{k}{\text{argmax}} s_k(u).$$

Далее в работе приводится исследование влияния упорядочивания классов по критерию разделимости. В результате данного исследования получены результаты, показывающие, что упорядочивание позволило повысить средние значения всех рассматриваемых метрик. Среднее значение F_2 увеличилось с 0,58 до 0,62, точности – с 0,53 до 0,57, полноты – с 0,64 до 0,66. В относительном выражении прирост составил приблизительно 6,9% для F_2 , 7,5% для точности и 3,1% для полноты.

Алгоритм A-MINDI является дальнейшим развитием алгоритмов INDI и MINDI и предназначен для автоматизированного анализа гиперспектральных изображений в условиях отсутствия исходной экспертной разметки. Если INDI решает задачу построения одного информативного индекса для бинарного разделения классов, а MINDI формирует упорядоченный ансамбль индексов для многоклассовой постановки «один против остальных», то A-MINDI дополнительно автоматизирует этап получения исходной разметки, необходимой для построения таких индексов. В рамках алгоритма гиперспектральное изображение сначала преобразуется к трехканальному представлению, пригодному для обработки нейросетевой моделью сегментации. Для этого используется метод главных компонент, позволяющий

сформировать изображение из наиболее информативных компонент исходного гиперспектрального изображения. Затем к полученному представлению применяется нейросетевая модель сегментации FastSAM, формирующая предварительный набор масок объектов. Полученные маски используются как автоматически сформированная предварительная разметка, на основе которой далее применяется алгоритм MINDI и строится ансамбль информативных нормализованных разностных индексов. На рисунке 3 представлена общая схема, демонстрирующая принцип работы алгоритма A-MINDI.



Рисунок 3 – Диаграмма, описывающая разработанный алгоритм A-MINDI

Для оценки применимости A-MINDI как метода автоматизированного формирования обучающих данных проведен эксперимент, в котором разметка, полученная данным алгоритмом, использовалась для обучения модели многослойного перцептрона (MLP). Эксперимент выполнялся на наборах данных Indian Pines, Salinas Valley, WHU-Hi (HanChuan, HongHu и LongKou). Сравнивались три варианта разметки: исходная эталонная разметка Y , предварительная разметка Y_{sam} , сформированная нейросетевой моделью FastSAM, и уточненная разметка Y_{amindi} , полученная после применения ансамбля информативных спектральных индексов A-MINDI. Для формирования обучающей выборки пиксели отбирались с учетом пространственной коррелированности данных: после выбора очередного пикселя из дальнейшего рассмотрения исключалась его локальная окрестность радиусом 5 пикселей. Полученная выборка разделялась на обучающую и тестовую части в соотношении 70/30, а качество обученной модели оценивалось по метрикам F_2 , точности и полноты.

Дополнительно была исследована согласованность сформированных разметок с исходной разметкой наборов данных с использованием метрики ARI. В таблице 1 представлены результаты данного эксперимента. Полученные значения показали, что разметка Y_{amindi} в меньшей степени совпадает с эталонной разметкой по структуре разбиения пикселей, чем предварительная разметка Y_{sam} . Однако данный результат не свидетельствует о снижении полезности A-MINDI, поскольку ARI характеризует

согласованность разбиений множества пикселей на классы, но не оценивает спектральную однородность выделенных классов и их разделимость в признаковом пространстве. Разметка FastSAM лучше сохраняет визуально целостные области изображения, тогда как разметка A-MINDI формируется на основе информативных спектральных индексов и поэтому может быть более согласована со спектральными признаками, используемыми при обучении модели машинного обучения.

Таблица 1 – Результаты исследования согласованности сформированных разметок с исходной

Изображение	$ARI(Y, Y_{sam})$	$ARI(Y, Y_{amindi})$	ΔARI
Salinas Valley	0,89	0,32	-0,57
Indian Pines	0,55	0,19	-0,36
LongKou	0,80	0,69	-0,11
HanChuan	0,38	0,16	-0,22
HongHu	0,94	0,26	-0,68

Результаты обучения многослойного перцептрона, представленные в таблице 2, подтвердили данное предположение. В большинстве случаев разметка Y_{amindi} , сформированная алгоритмом A-MINDI, оказалась более пригодной для обучения модели MLP, чем предварительная разметка Y_{sam} и исходная разметка Y . Данный эксперимент показал, что A-MINDI может использоваться не только как метод автоматизированного анализа гиперспектральных изображений, но и как средство формирования обучающих данных для последующего обучения моделей машинного обучения.

Таблица 2 – Сравнение результатов обучения модели MLP на разных разметках и наборах данных

Разметка	Метрика	Indian Pines	Salinas	HanChuan	HongHu	LongKou
Y_{amindi}	F_2	0,84	0,82	0,82	0,92	0,86
	Precision	0,84	0,82	0,82	0,92	0,84
	Recall	0,85	0,83	0,83	0,93	0,86
Y_{sam}	F_2	0,17	0,67	0,83	0,76	0,88
	Precision	0,15	0,76	0,83	0,74	0,90
	Recall	0,18	0,67	0,83	0,77	0,87
Y	F_2	0,12	0,43	0,70	0,79	0,90
	Precision	0,06	0,46	0,72	0,78	0,88
	Recall	0,16	0,45	0,70	0,79	0,91

Кроме алгоритмов INDI, MINDI и A-MINDI, в третьей главе рассмотрены дополнительные методы, необходимые для построения функционально полного программного комплекса: анализ с использованием схожести с эталоном, обработка с использованием вегетационных индексов, анализ методом К-средних, методы предварительной нормировки данных, метод мозаичной обработки, алгоритм цветосинтеза и метод эффективного хранения гиперспектральных изображений. Метод мозаичной обработки позволяет формировать представления больших гиперспектральных изображений, удобные для интерактивной визуализации. Алгоритм цветосинтеза обеспечивает построение псевдоцветного представления

гиперспектральных данных по выбранным каналам, что необходимо для визуального анализа пользователем.

В заключении сформулированы основные результаты работы.

В результате выполнения диссертационной работы разработана интеллектуальная облачная система для автоматизации обработки гиперспектральных изображений, обеспечивающая формирование информативных признаков, предварительную разметку данных, хранение, визуализацию, анализ и возможность интеграции пользовательских алгоритмов в единой программной среде.

Разработана архитектура интеллектуальной системы обработки гиперспектральных изображений, отличающаяся выделением независимых компонентов управления исходными данными, результатами анализа и визуализации, постановки вычислительных задач и выполнения алгоритмов. Такое разделение обеспечивает горизонтальное масштабирование компонентов, асинхронное выполнение ресурсоёмких операций и функциональное расширение системы.

На основе предложенной архитектуры реализована интеллектуальная система, обеспечивающая централизованное хранение гиперспектральных изображений, интерактивную визуализацию, выполнение алгоритмов анализа, сохранение и повторное использование результатов обработки. Среднее значение метрики МТТА при интеграции алгоритмов K-means и PCA по результатам 10 запусков составило 1,51 с без учёта первичной загрузки контейнерного образа. При подключении новых алгоритмов изменение исходного кода существующих компонентов и простоя системы не потребовалось. В ходе нагрузочного тестирования в распределённой среде из двух вычислительных узлов отказов компонентов не зафиксировано. Максимальная пропускная способность отдельных компонентов составила 1410,4, 914,6 и 142,8 запроса в секунду, а в режиме, имитирующем поведение реальных пользователей, средние задержки составили соответственно 45,81, 40,79 и 315,94 мс.

Впервые разработан алгоритм INDI, отличающийся автоматическим отбором пары спектральных полос для формирования информативного нормализованного разностного индекса в бинарной постановке задачи. При разделении классов «Сельдерей» и «Стерня» на изображении значение F_2 составило 0,79 против 0,73 для NDVI. В задачах обнаружения нефтяных загрязнений и очагов лесных пожаров получены значения F_2 , равные 0,74 и 0,94, а значения AUC составили соответственно 0,991 и 0,998. Полученные результаты подтверждают применимость алгоритма к различным задачам анализа гиперспектральных и мультиспектральных данных.

Разработан алгоритм MINDI для формирования ансамбля информативных индексов, расширяющий подход INDI на случай многоклассовой сегментации за счёт последовательного решения задач «один против остальных» и упорядочивания классов по критерию отделимости. В проведённом эксперименте среднее значение метрики F_2 увеличилось с 0,58 при формировании ансамбля без учёта отделимости классов до 0,62 при использовании алгоритма MINDI, учитывающего отделимость классов при определении порядка их обработки.

Разработан алгоритм A-MINDI для автоматического формирования ансамбля информативных индексов и предварительной разметки гиперспектральных изображений. Алгоритм предназначен для снижения объёма ручной разметки при подготовке данных к последующему применению нейросетевых методов. Применимость A-MINDI для автоматизации анализа гиперспектральных изображений подтверждена экспериментами с обучением модели многослойного

перцептрона: при использовании разметки, сформированной A-MINDI, среднее по пяти исследованным наборам данных значение метрики F_2 составило 0,852.

Разработанные алгоритмы и интеллектуальная система могут применяться для автоматизации анализа гиперспектральных изображений в научных и прикладных задачах, включая формирование информативных спектральных признаков и предварительной разметки данных. Перспективы дальнейших исследований связаны с совершенствованием методов автоматизированного анализа в условиях отсутствия экспертной разметки, повышением качества формируемых спектральных признаков и расширением функциональных возможностей интеллектуальной системы за счёт интеграции новых базовых алгоритмов и моделей машинного обучения.

Публикации автора по теме диссертации

В изданиях, входящих в международные базы цитирования Web of Science и Scopus:

1. Automated Lightweight Descriptor Generation for Hyperspectral Image Analysis / **A. Mukhin**, R. Paringer, D. Gribanov, I. Kilbas // Optical Memory and Neural Networks. – 2024. – Vol. 33. – No. 3. – P. 264-275.
2. **Mukhin, A.** Semantic Segmentation of Hyperspectral Imaging Using Convolutional Neural Networks / A. Mukhin, G. Danil, R. Paringer // Optical Memory and Neural Networks. – 2022. – Vol. 31. – No. 1. – P. 38-47.

В изданиях из списка ВАК РФ:

3. Парингер, Р.А. Формирование информативного индекса для различения заданных объектов гиперспектральных данных / Р.А. Парингер, **А.В. Мухин**, А.В. Куприянов // Компьютерная оптика. – 2021. – Т. 45. – № 6. – С. 873-878.
4. Семантическая сегментация гиперспектральных изображений с использованием сверточных нейронных сетей и механизма внимания / Д.Н. Грибанов, **А.В. Мухин**, И.А. Килбас, Р.А. Парингер // Компьютерная оптика. – 2024. – Т. 48. – № 6. – С. 894-902.
5. **Мухин, А.В.** Разработка расширяемой микросервисной архитектуры программного комплекса анализа данных / А.В. Мухин // Информационные технологии и вычислительные системы. – 2025. – № 3. – С. 73-85.

В сборниках трудов конференций:

6. Алгоритм автоматического построения компактных дескрипторов сегментирующих гиперспектральные изображения / **А.В. Мухин**, Р.А. Парингер, Д.Н. Грибанов [и др.] // X Международная конференция и молодёжная школа «Информационные технологии и нанотехнологии» (ИТНТ-2024). – 2024. – Т. 4. – С. 040372.
7. **Мухин, А.В.** Алгоритм отбора информативных признаков на основе оценки разделяющей способности пространства признаков с использованием дискриминантного анализа / А.В. Мухин, Р.А. Парингер, Н.Ю. Ильясова // VII Международная конференция и молодёжная школа «Информационные технологии и нанотехнологии» (ИТНТ-2021). – 2021. – Т. 3. – С. 30162.
8. **Мухин, А.В.** Применение нейросетевых алгоритмов для решения задачи семантической сегментации гиперспектральных данных / А.В. Мухин, Д.Н. Грибанов, Р.А. Парингер // Информационные технологии и нанотехнологии (ИТНТ-2022). – 2022. – Т. 4. – С. 40102.

Полученные государственные свидетельства о регистрации программы для ЭВМ:

9. Свидетельство о государственной регистрации программы для ЭВМ № 2020666922. Модуль формирования информативных индексов для различения заданных объектов гиперспектральных данных: заявлено 12.10.2020: опубликовано 17.12.2020 / **Мухин А.В.**, Парингер Р.А., Куприянов А.В.; заявитель Самарский Университет. – 1 с.
10. Свидетельство о государственной регистрации программы для ЭВМ № 2021663888. Облачный сервис анализа гиперкубов hyperspectrum.copter.space: заявлено 18.06.2021: опубликовано 25.08.2021 / Парингер Р.А., **Мухин А.В.**; заявитель Общество с ограниченной ответственностью «Байт-Самара». – 1 с.
11. Свидетельство о государственной регистрации программы для ЭВМ № 2021669454. Модуль итерационного составления набора информативных признаков для различения множества классов учитывающий отделимость классов в пространстве признаков: заявлено 17.11.2021: опубликовано 29.11.2021 / **Мухин А.В.**, Парингер Р.А., Куприянов А.В., Килбас И.А.; заявитель Самарский Университет. – 1 с.
12. Свидетельство о государственной регистрации программы для ЭВМ № 2022665368. Модуль обучения нейросетевого дескриптора для анализа мультиспектральных данных: заявлено 29.06.2022: опубликовано 15.08.2022 / **Мухин А.В.**, Парингер Р.А., Грибанов Д.Н., Килбас И.А.; заявитель Самарский Университет. – 1 с.
13. Свидетельство о государственной регистрации программы для ЭВМ № 2023610529. Модуль исследования применимости методов машинного обучения для обработки гиперспектральных данных: заявлено 15.12.2022: опубликовано 11.01.2023 / **Мухин А.В.**, Грибанов Д.Н., Парингер Р.А., Килбас И.А.; заявитель Самарский Университет. – 1 с.
14. Свидетельство о государственной регистрации программы для ЭВМ № 2023680048 Российская Федерация. Программный модуль оценки информативности и отбора признаков, формирующих эффективное признаковое пространство: заявлено 19.09.2023: опубликовано 25.09.2023 / **Мухин А.В.**, Парингер Р.А., Куприянов А.В.; заявитель Самарский Университет. – 1 с.
15. Свидетельство о государственной регистрации программы для ЭВМ № 2023682920. Программный модуль автоматического формирования легковесных дескрипторов для анализа гиперспектральных данных: заявлено 23.10.2023: опубликовано 01.11.2023 / Килбас И.А., Грибанов Д.Н., **Мухин А.В.**, Парингер Р.А.; заявитель Самарский Университет. – 1 с.
16. Свидетельство о государственной регистрации программы для ЭВМ № 2024615474. Открытая платформа для обработки и анализа спектральных изображений: заявлено 26.02.2024: опубликовано 07.03.2024 / **Мухин А.В.**; заявитель Мухин Артем Владимирович. – 1 с.