

На правах рукописи

Макаров Андрей Романович

**МЕТОД И НЕЙРОСЕТЕВЫЕ
АЛГОРИТМЫ ПОВЫШЕНИЯ ТОЧНОСТИ
ПОЭЛЕМЕНТНОЙ КЛАССИФИКАЦИИ
ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ**

1.2.1. Искусственный интеллект и машинное обучение

АВТОРЕФЕРАТ
диссертации на соискание учёной степени
кандидата технических наук

Самара – 2026

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

Научный руководитель:

Никоноров Артем Владимирович, доктор технических наук, доцент, федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева», профессор кафедры киберфотоники.

Официальные оппоненты:

Николаев Дмитрий Петрович, доктор технических наук, доцент, федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук», руководитель отдела зрительных систем;

Юдин Дмитрий Александрович, кандидат технических наук, федеральное государственное автономное образовательное учреждение высшего образования «Московский физико-технический институт (национальный исследовательский университет)», заведующий лабораторией интеллектуального транспорта.

Ведущая организация:

Федеральное государственное автономное образовательное учреждение высшего образования «Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)», г. Санкт-Петербург.

Защита состоится 18 декабря 2026 года в 12:00 на заседании диссертационного совета 24.2.379.09, созданного на базе федерального государственного автономного образовательного учреждения высшего образования «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 федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева»: <https://ssau.ru/storage/pages/makarov>.

Автореферат разослан «_____» _____ 2026 г.

Учёный секретарь диссертационного совета,
доктор физико-математических наук, доцент

А.В. Дорошин

Общая характеристика работы

Актуальность

Гиперспектральное изображение (ГСИ) содержит значения зарегистрированного сигнала в узких спектральных поддиапазонах. Гиперспектральная съёмка применяется в дистанционном зондировании Земли, сельском хозяйстве, экологическом мониторинге и анализе материалов. Регистрация спектральной информации позволяет выявлять различия между объектами, которые могут быть неразличимы на RGB-изображениях. При поэлементной классификации каждому спектральному вектору в пространственной позиции ГСИ присваивается метка одного из заданных классов. В настоящей работе ГСИ представляется в виде тензора третьего порядка с двумя пространственными и одной спектральной осями.

При сканирующей съёмке гиперспектральная аппаратура (ГСА) последовательно регистрирует пространственные спектрограммы, из которых формируется ГСИ. Пространственное рассогласование, неоднородность отклика и зависимость спектральных характеристик от положения вдоль щели влияют на получаемые данные. Время экспозиции и усиление определяют уровень сигнала и шума; предобработка и сжатие также изменяют данные, используемые классификатором.

Показатели качества, основанные на сопоставлении с эталоном, в том числе пиковое отношение сигнала к шуму (PSNR), индекс структурного сходства (SSIM) и спектральный угол (SAM), характеризуют различия между изображениями без учёта меток классов. Их связь с точностью поэлементной классификации требует исследования для заданной целевой задачи. Поэтому актуальны разработка процедур оценки качества ГСИ и методов предобработки и коррекции отклика гиперспектрометров, позволяющих выбирать параметры формирования и обработки данных с учётом точности классификации.

Степень разработанности темы

Спектральные характеристики природных объектов исследованы в работах Е. Л. Кринова; вопросы формирования, обработки и анализа данных дистанционного зондирования рассмотрены в трудах Р. А. Шовенгердта. Формированию и анализу ГСИ, разработке гиперспектральной аппаратуры и методов поэлементной классификации ГСИ посвящены работы В. А. Сойфера, Н. Л. Казанского, Р. В. Скиданова, Н. И. Глумова, В. В. Сергеева, В. В. Мясникова, Е. В. Мясникова, А. В. Куприянова, Г. Кэмпс-Вальса, Ф. Мелгани, Ч.-И. Чанга.

Для выбора параметров формирования и обработки ГСИ необходимо исследовать связь показателей качества с точностью классификации, а также возможность настройки предобработки и коррекции с учётом целевой задачи. В настоящей работе рассматриваются сопоставление спектрально близких классов реальных ГСИ и ГСИ печатных сцен, формирование калибровочной сцены и её использование для настройки нейросетевой спектральной предобработки и позиционно-зависимой коррекции.

Целью работы является повышение точности поэлементной классификации гиперспектральных изображений за счёт выбора параметров их формирования, предобработки и коррекции.

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

- 1) Разработать методику оценки качества ГСИ, полученных сканирующей ГСА, согласующуюся с точностью поэлементной классификации гиперспектрального изображения.
- 2) На основе методики оценки качества ГСИ разработать алгоритмы формирования и предобработки ГСИ, в том числе нейросетевые, обеспечивающие повышение точности поэлементной классификации.
- 3) Разработать алгоритмы коррекции пространственно-спектральных искажений ГСИ, в том числе нейросетевые, ориентированные на повышение точности решения задачи поэлементной классификации.
- 4) Провести экспериментальную проверку разработанных методов и алгоритмов на гиперспектральных данных, полученных различной гиперспектральной аппаратурой, а также на открытых наборах ГСИ.

Научная новизна работы состоит в следующих впервые полученных результатах:

1) Предложен показатель качества ГСИ на основе точности классификации в целевой задаче (ТКЦЗ), получено теоретическое и экспериментальное подтверждение его преимущества перед метриками сопоставления с эталонным ГСИ, разработана методика использования ТКЦЗ для повышения точности решения задачи поэлементной классификации.

2) Разработаны метод и нейросетевые алгоритмы спектральной предобработки ГСИ, а также методика выбора параметров формирования ГСИ, таких как усиление камеры, время экспозиции и параметры сжатия, с оптимизацией по критерию ТКЦЗ.

3) Разработаны нейросетевые алгоритмы позиционно-зависимой коррекции пространственно-спектральных искажений ГСИ с оптимизацией по критерию ТКЦЗ, реализованные в виде калибровочных слоёв, переносимых между различными нейросетевыми классификаторами.

Практическая значимость

Предложенная методика описывает формирование калибровочной сцены, на основе которой подбираются параметры съёмки, предобработки и калибровки гиперспектрометров по критерию точности классификации целевой задачи (ТКЦЗ). Использование ТКЦЗ в качестве оптимизационного критерия позволило создать метод обучаемой нейросетевой предобработки и калибровки ГСИ. На его основе разработаны нейросетевые алгоритмы спектральной предобработки, а также нейросетевые калибровочные слои, переносимые между различными свёрточными и трансформерными классификаторами. Разработанные нейросетевые алгоритмы предобработки и калибровки позволяют существенно повысить точность поэлементной классификации в сравнении с существующими аналогами, в том числе проприетарными алгоритмами улучшения изображений гиперспектрометра Specim.

Результаты работы внедрены в Центре «Интеллектуальная мобильность многофункциональных беспилотных авиационных систем» и использовались в рамках проекта «Разработка фреймворка дистанционного мониторинга на основе интеллектуального анализа мультимодальных данных, полученных на борту беспилотных авиационных систем FW_Monitor» (Приложение А).

Результаты работы внедрены в ООО «Локус» и используются в рамках проекта «Разработка открытой платформы сбора и анализа гиперспектральных

изображений для решения прикладных задач цифровой экономики» (Приложение Б).

Результаты работы были запатентованы как «Метод поиска загрязнений водной поверхности» (патент на изобретение № 2840891) (Приложение В).

Методология и методы исследования. Используются методы математического моделирования формирования ГСИ, корреляционного анализа, обработки изображений и спектральных данных, спектрального сглаживания, гребневой регрессии и обучения нейронных сетей. Экспериментальная оценка выполняется по метрикам качества, основанным на сопоставлении с эталоном, общей точности поэлементной классификации (Overall Accuracy, OA), полноте и F1-мере класса, а также взвешенной F1-мере.

Соответствие паспорту специальности. Диссертация соответствует паспорту научной специальности 1.2.1 «Искусственный интеллект и машинное обучение» и охватывает следующие области исследования, входящие в данную специальность:

4. Разработка методов, алгоритмов и создание систем искусственного интеллекта и машинного обучения для обработки и анализа текстов на естественном языке, для изображений, речи, биомедицины и других специальных видов данных.

13. Методы и средства формирования массивов данных и прецедентов, включая «большие данные», необходимых для решения задач искусственного интеллекта и машинного обучения. Проблемно-ориентированные коллекции данных для важных прикладных областей.

17. Исследования в области многослойных алгоритмических конструкций, в том числе – многослойных нейросетей.

Основные положения, выносимые на защиту:

1. Предложена методика формирования калибровочной сцены для сканирующих гиперспектрометров, с оценкой показателя точности классификации в целевой задаче (ТКЦЗ), являющаяся более устойчивой к малым пространственным рассогласованиям между ГСИ, чем классические метрики PSNR, SSIM и SAM, основанные на сравнении с эталонным изображением.

2. Разработан нейросетевой алгоритм спектрального сглаживания и коррекции уровня чёрного в ГСИ позволяющий повысить точность поэлементной классификации с использованием свёрточных (1DCNN, NM3DCNN) и трансформерных нейросетевых классификаторов (SSFTT), прирост точности относительно варианта без дополнительной предобработки составляет от 2,17 до 6,22 п.п., прирост взвешенной F1-меры – от 2,03 до 7,68 п.п., а прирост PSNR между средними спектральными векторами классов – от 0,268 до 0,695 дБ. По сравнению с нейросетевыми аналогами применение предложенного алгоритма позволило повысить общую точность поэлементной классификации на 0,94–1,45 п.п., прирост взвешенной F1-меры – от 0,94 до 1,47 п.п.

3. Разработана методика выбора параметров формирования ГСИ с оптимизацией по критерию ТКЦЗ, экспериментально показано, что определение усиления камеры, времени экспозиции и параметров сжатия по этой методике обеспечивает повышение точности классификации на тестовой сцене на 1,81; 0,90 и 2,51 п.п. для 1DCNN, NM3DCNN и SSFTT соответственно.

4. Разработаны алгоритмы обучаемой позиционно-зависимой коррекции ГСИ в виде переносимых калибровочных слоёв, обеспечивающие прирост точности

поэлементной классификации ГСИ для свёрточных и трансформерных классификаторов от 0,65 до 8,83 п.п., прирост взвешенной F1-меры – от 1,15 до 10,43 п.п., по сравнению с ГСИ без калибровки. По сравнению с калибровкой по белому эталону соответствующие приросты составили от 0,20 до 1,57 п.п. и от 0,51 до 1,56 п.п.

Достоверность полученных результатов подтверждена посредством воспроизводимых вычислительных экспериментов по поэлементной классификации на наборах гиперспектральных изображений, полученных различной ГСА, в том числе коммерческой ГСА Specim, а также на открытых наборах ГСИ высокого пространственного разрешения. Часть собранных наборов гиперспектральных изображений и разработанных нейросетевых моделей выложена в общий доступ. Описания предложенных методов и алгоритмов обработки ГСИ допускают их воспроизводимость и опубликованы в ведущих научных журналах и трудах конференций по машинному зрению и обработке изображений.

Апробация работы. Результаты работы представлены на международных конференциях International Joint Conference on AI (IJCAI) A*, 2026, (Бремен, Германия), International Conference on Embedded Artificial Intelligence and Sensing Systems (SenSys) A*, 2026, (Сен-Мало, Франция), X International conference on information technology and nanotechnology (ITNT – 2024), (Самара), 2024, International Conference on Machine Vision (ICMV 2026), (Будапешт, Венгрия), 2026.

Авторский вклад в работу является определяющим. Все изложенные в работе и выносимые на защиту результаты получены автором лично. Постановка задач и формализация результатов проводились совместно с научным руководителем. В диссертации использованы результаты совместных исследований: Формирование и подготовка наборов ГСИ проводились совместно с Н.А. Ивлиевым, В.В. Подлипновым, Д.М. Владимировым и К.Э. Савельевым. Исследованная гиперспектральная аппаратура разработана Н.Л. Казанским, Р.В. Скидановым, Н.А. Ивлиевым и В.В. Подлипновым.

Публикации. Основные результаты по теме диссертации изложены в 13 печатных работах, 7 – в журналах, индексируемых Scopus и Web of Science, приравненных к журналам Перечня ВАК, в т.ч. 1 Q1, 3 Q2, 3 Q3, 6 – в прочих изданиях, индексируемых Scopus и Web of Science, в т.ч. 3 конференции ранга A*. Основные результаты опубликованы в 5.

Объём и структура работы. Диссертация состоит из введения, трёх глав, заключения, списка литературы и трёх приложений. Объём диссертации составляет 212 страниц, включая 72 рисунка и 27 таблиц. Список литературы содержит 147 наименований.

Основное содержание работы

Во введении обоснована актуальность темы и охарактеризована степень её разработанности. Сформулированы цель и задачи исследования, научная новизна, теоретическая и практическая значимость, методы исследования и основные положения, выносимые на защиту. Приведены сведения об апробации результатов, публикациях и структуре работы.

В первой главе разрабатывается методика формирования и применения печатной калибровочной сцены для выбора параметров получения и обработки ГСИ по точности поэлементной классификации. Для её обоснования исследуются влияние пространственного рассогласования на показатели качества и

согласованность изменений показателей классификации реальных и печатных спектров.

В разделе 1.1 описан процесс формирования ГСИ щелевой сканирующей гиперспектральной аппаратурой (СГСА). В ряде работ ГСИ представляют в виде матричной развёртки, в которой пространственные позиции объединены вдоль одной оси, а спектральные каналы расположены вдоль другой. Для описания калибровки в данной работе используется тензор третьего порядка. Приведена интегральная модель формирования пространственной спектрограммы. Рассмотрены перенос и относительный поворот проекций щелевой диафрагмы в плоскости сцены; получены соотношения для смещений пространственных отсчётов.

В разделе 1.2 получены выражения, связывающие PSNR, SSIM и SAM с коэффициентом корреляции Пирсона при линейном сдвиге. При равных средних значениях и одинаковом ненулевом стандартном отклонении сравниваемых данных:

$$\text{PSNR}(d) = 10 \log_{10} \frac{L^2(d)}{2\sigma^2(1-\rho_d)}, \quad (1)$$

где d – величина линейного сдвига; ρ_d – корреляция Пирсона по всем каналам на области сравнения при сдвиге d ; σ – общее стандартное отклонение данных на этой области; $L(d)$ – максимальное значение элемента эталонного ГСИ на ней. Для SSIM и SAM корреляция рассчитывается по локальным окнам каналов и отдельным спектрам соответственно.

Определена общая точность поэлементной классификации и рассмотрено её изменение при пространственном рассогласовании массивов меток.

В разделе 1.3 экспериментально исследовано влияние линейного сдвига на показатели качества и точность классификации ГСИ набора NTIRE 2022 и участков речных массивов, снятых СГСА, установленной на беспилотную авиационную систему (БАС). Сопоставлены эталонное ГСИ, зашумлённое ГСИ и ГСИ после пространственного размытия и внесения шума. При расчёте PSNR, SSIM и SAM сдвигалось оцениваемое ГСИ относительно эталонного; при расчёте ОА – массив предсказанных меток относительно эталонной разметки. В исследованном диапазоне сдвигов порядок вариантов по ОА сохранялся, тогда как порядок по PSNR, SSIM и SAM изменялся. На сцене ARAD_1K_0927 дополнительно сопоставлены зашумлённый и размытый с внесением шума варианты ГСИ с использованием 1DCNN, NM3DCNN и SSFTT. Приведена эмпирическая аппроксимация снижения ОА в зависимости от величины сдвига и числа классов при фиксированном размере массива вдоль направления сдвига.

В разделе 1.4 сопоставлены по общей точности классификации ГСИ Specim IQ, ГСИ разработанного гиперспектрометра с оптической схемой Оффнера, и ГСИ, восстановленное методом MST++ по RGB-представлению ГСИ Specim IQ. Данные приведены к общей сетке длин волн. Классификаторы 1DCNN, NM3DCNN и SSFTT обучались на данных Specim IQ и применялись к двум другим вариантам ГСИ без дообучения.

В разделе 1.5 исследована согласованность изменений показателей классификации реальных ГСИ набора NTIRE 2022 и их печатных представлений, образующих разные домены. ГСИ печатных сцен синтезированы по RGB-представлениям этих данных с использованием модели цветной печати. При добавлении гауссовского шума одинакового относительного уровня сопоставлялись

изменения полноты и F1-меры соответствующих классов, а на уровне фрагментов ГСИ с несколькими классами – общей точности и взвешенной F1-меры. Методика формирования печатной калибровочной сцены предусматривает отбор спектрально близких печатных и реальных классов с согласованными изменениями показателей классификации и применение сцены для выбора параметров съёмки, предобработки и калибровки по ТКЦЗ. Классы калибровочной сцены подбираются с учётом состава классов целевой задачи. Оценка по ТКЦЗ проводится для заданного состава классов при фиксированной архитектуре классификатора и протоколе его обучения и проверки. Если при настройке требуется учесть новые классы, калибровочный слой обучают заново либо дообучают с учётом расширенного состава классов.

В разделе 1.6 предлагается набор классов печатной калибровочной сцены и проверяется его соответствие классам реальных ГСИ набора NTIRE 2022. Для отобранных спектрально близких пар классов установлена согласованность изменений показателей классификации при добавлении гауссовского шума.

Число классов NTIRE (1809 классов) с согласованными изменениями показателей классификации для каждого класса калибровочной сцены показано на рисунке 1.




Рисунок 1 – Число классов реальных ГСИ NTIRE для каждого класса калибровочной сцены при коэффициенте корреляции Спирмена $\rho > 0,7$

На основе разработанной методики сформирована печатная калибровочная сцена. Во второй главе её ГСИ используются для настройки спектральной предобработки и исследования возможности выбора параметров съёмки и сжатия. В третьей главе эта сцена применяется для настройки обучаемой позиционно-зависимой коррекции отклика гиперспектрометра.

Во второй главе ГСИ печатной калибровочной сцены, разработанной в первой главе, используются для настройки спектральной предобработки. Исследуется влияние параметров формирования и обработки ГСИ на точность поэлементной классификации. Рассматриваются настройка спектральной предобработки, включающей спектральное шумоподавление и программную коррекцию уровня чёрного, выбор видеокодеков и параметров сжатия, а также изменение времени экспозиции и усиления. В качестве критерия оценки и выбора рассматриваемых настроек используется ТКЦЗ.

В разделе 2.1 рассматривается настройка обучаемого модуля спектральной предобработки – коэффициентов спектральной свёртки и программной поправки уровня чёрного. Аналитическая настройка выполняется методом гребневой регрессии, нейросетевая настройка выполняется по функции ошибки на основе перекрёстной энтропии L_{CE} либо комбинированной функции ошибки L_{CE_MSE} , включающей средний квадрат ошибки L_{MSE} между средними спектральными векторами соответствующих классов. Базовый вариант спектральной предобработки

– сглаживание фильтром Савицкого–Голея. Архитектура спектральной предобработки ГСИ с обучаемым модулем представлена на рисунке 2.



Рисунок 2 – Архитектура спектральной предобработки ГСИ с обучаемым модулем

Далее в главе 3 будет показано, что метод нейросетевой предобработки ГСИ позволяет также реализовать обучаемые нейросетевые калибровочные слои для коррекции пространственно-спектральных искажений ГСИ.

В разделе 2.2 описаны ГСИ калибровочной и тестовой сцен, варианты предобработки и протокол обучения классификаторов 1DCNN, NM3DCNN и SSFTT. Параметры, определённые по калибровочной сцене, применяются к тестовой сцене без дополнительной настройки. Для каждого классификатора варианты предобработки сопоставляются при заданном составе классов и едином протоколе обучения и проверки. Результаты оцениваются по ОА, взвешенной F1-мере и PSNR между средними спектральными векторами классов тестового и опорного ГСИ. В обучаемом модуле коэффициенты спектральной свёртки β и программная поправка уровня чёрного d_0 определяются по калибровочной сцене. Алгоритм настройки оператора предобработки записывается в виде (2):

$$S_{out} = F(S, \theta^*)$$

$$(\theta^*, \psi^*) = \arg \min_{\theta, \psi} [L_{CE}(C_\psi(F(S, \theta)), c_e) + \lambda L_{MSE}(F(S, \theta), S_e)] \quad (2)$$

где S и S_{out} – исходное и преобразованное ГСИ; F – оператор преобразования с параметрами θ ; C_ψ – классификатор с параметрами ψ ; c_e – метки классов; S_e – набор опорных спектров классов, полученных по известному эталонному ГСИ или заданным требованиям к спектрам; L_{CE} – категориальная перекрёстная энтропия, вычисляемая по вероятностям классов; L_{MSE} – спектральная ошибка; $\lambda \geq 0$ – её вес.

В дополнительных исследованиях по средней валидационной ОА выбраны окно фильтра Савицкого–Голея длиной 5 каналов и коэффициент λ комбинированной функции ошибки: 0,1 при настройке с 1DCNN, 0,01 с NM3DCNN и 1 с SSFTT. В таблице 1 приведены результаты настройки с 1DCNN и оценки с SSFTT. Вариант без дополнительной предобработки включает нормирование по белому эталону при нулевой программной поправке уровня чёрного. Для нейросетевых вариантов и фильтра Савицкого–Голея представлены средние значения и выборочное стандартное отклонение (SD) по десяти запускам для каждого варианта с различной случайной инициализацией. Также проведено сравнение с нейросетевым алгоритмом спектрального сглаживания (Gabriel Michau et al., 2022).

Таблица 1 – Результаты на тестовой сцене: настройка предобработки с 1DCNN, оценка с SSFTT; $\lambda = 0,1$ для комбинированного критерия

Вариант предобработки	ОА	Взвешенная F1-мера	PSNR, дБ
Без дополнительной предобработки	0,9405	0,9418	23,409
Фильтр Савицкого–Голея (окно 5)	$0,9497 \pm 0,0086$	$0,9477 \pm 0,0076$	23,490
Обучаемая предобработка, функция ошибки на основе перекрёстной энтропии	$0,9619 \pm 0,0120$	$0,9610 \pm 0,0139$	$24,037 \pm 0,027$
Определение параметров предобработки на основе гребневой регрессии	0,9509	0,9501	24,016
Обучаемая предобработка, комбинированная функция ошибки	$0,9737 \pm 0,0096$	$0,9736 \pm 0,0063$	$24,104 \pm 0,009$

При настройке с 1DCNN по комбинированной функции ошибки и оценке с SSFTT прирост средней ОА составил 3,32 процентного пункта относительно варианта без дополнительной предобработки и 2,40 процентного пункта относительно фильтра Савицкого–Голея (таблица 1). В рассмотренных условиях средняя ОА также превысила результаты DeSpaWN и DeCWN (таблица 2).

Таблица 2 – Результаты применения DeSpaWN и DeCWN с классификатором SSFTT, настройка при использовании 1DCNN

Модель	Функция ошибки	ОА	Взвешенная F1-мера	PSNR, дБ	Число параметров
DeSpaWN	Перекрёстная энтропия	$0,9643 \pm 0,0023$	$0,9642 \pm 0,0046$	$23,887 \pm 0,015$	52
	Комбинированная	$0,9642 \pm 0,0057$	$0,9642 \pm 0,0033$	$24,004 \pm 0,008$	
DeCWN	Перекрёстная энтропия	$0,9592 \pm 0,0054$	$0,9589 \pm 0,0042$	$23,890 \pm 0,021$	20
	Комбинированная	$0,9621 \pm 0,0073$	$0,9614 \pm 0,0061$	$24,056 \pm 0,011$	

Для метода опорных векторов (SVM), метода k ближайших соседей (kNN) и многослойного персептрона (MLP) наибольшая средняя ОА получена при настройке предобработки с 1DCNN; приросты относительно варианта без дополнительной предобработки составили 11,85; 0,72 и 1,22 процентного пункта соответственно. Взвешенная F1-мера повысилась для SVM и несколько снизилась для kNN и MLP.

В разделе 2.3 рассматриваются две серии вычислительных экспериментов. В первой серии экспериментов время экспозиции сокращается с 10 до 0,357 мс при увеличении усиления с 1 до 28; во второй серии экспериментов усиление изменяется от 1 до 28 при фиксированной экспозиции 0,357 мс. Для каждого режима классификаторы обучаются независимо. Результаты экспериментов со сжатием и параметрами съёмки представлены средними значениями по трём запускам без оценки разброса. Зависимости ОА от усиления на калибровочной и тестовой сценах приведены на рисунке 3.




Рисунок 3 – Зависимости ОА от усиления при экспозиции 0,357 мс для ГСИ печатной калибровочной (а) и тестовой (б) сцен; средние значения по трём запускам

В разделе 2.4 исследуется влияние сжатия видеокодеками H.264, H.265 и MJPEG на точность поэлементной классификации. Сопоставляются линейное преобразование и гамма-кодирование цифровых отсчётов. Классификаторы обучаются на данных без видеосжатия. На ГСИ печатной калибровочной и тестовой сцен наблюдаются сходные общие тенденции изменения ОА, при этом выраженность и положение отдельных участков снижения точности различаются.

В разделе 2.5 обсуждаются результаты: наибольшему PSNR после предобработки не всегда соответствует наибольшая ОА, а сохранение среднего цифрового отсчёта при сокращении экспозиции не обеспечивает сохранения точности. В рассмотренных условиях выбор усиления целесообразно ограничить диапазоном 1–16, определяя конкретное значение по результатам классификации ГСИ печатной калибровочной сцены.

В разделе 2.6 сформулированы выводы о настройке спектральной предобработки и влиянии сжатия, времени экспозиции и усиления на точность классификации. Протокол настройки по калибровочной сцене и оценки на отдельной тестовой сцене используется далее при исследовании обучаемой позиционно-зависимой коррекции в третьей главе.

В третьей главе предложенный метод реализуется посредством обучаемой позиционно-зависимой коррекции отклика гиперспектрометра. Корректирующие коэффициенты зависят от положения вдоль оси длины щелевой диафрагмы и спектральной оси. Для их настройки используются ГСИ печатной калибровочной сцены первой главы и протокол оценки, применённый во второй главе. Варианты коррекции оцениваются для заданного состава классов при фиксированных архитектуре классификатора и протоколе его обучения и проверки.

В разделе 3.1 рассмотрены пространственно-спектральное рассогласование, неоднородность чувствительности и методы их коррекции. Описаны калибровка по объектам с известными спектральными характеристиками, влияние условий регистрации на переносимость калибровочных коэффициентов и нейросетевые методы коррекции ГСИ.

В разделе 3.2 приведена модель неоднородности чувствительности и сформулированы задачи для двух алгоритмов. В алгоритме № 1 коррекция определяется по опорным спектрам классов калибровочной сцены разработанного гиперспектрометра, в алгоритме № 2 – по средним спектрам соответствующих классов Specim IQ при межприборном сопоставлении.

В разделе 3.3 описаны матричная и векторная параметризации калибровочных слоёв и их сочетания с полиномиальной составляющей. Коэффициенты инициализируются методом гребневой регрессии и уточняются при

нейросетевом дообучении по перекрёстной энтропии или комбинированной функции ошибки. После настройки коэффициенты фиксируются для применения к другим сценам. Калибровочные слои описаны в работе [3].

В матричной конфигурации «m» используется обучаемая матрица $M \in R^{J \times K}$:

$$S_m(i, j, k) = S(i, j, k) \odot M(j, k), \quad (3)$$

где $M(j, k)$ – коэффициент коррекции для глобального положения j вдоль щели и спектрального канала k ; J и K – число отсчётов вдоль щели и спектральных каналов. При обработке фрагментов коэффициенты выбираются по глобальным координатам столбцов в исходном ГСИ.

Векторная конфигурация «v» задаёт коэффициент коррекции как произведение пространственного и спектрального множителей из двух обучаемых векторов; число параметров уменьшается с JK до $J + K$. Полиномиальный слой формирует для каждого канала пространственный вектор множителей по квадратичному полиному от координаты вдоль щели, нормированной на интервал $[0, 1]$. В конфигурациях «pm» и «pv» каждый отсчёт сначала умножается на полиномиальный коэффициент, затем применяется соответственно матричная или векторная коррекция.

Перекрёстная энтропия и комбинированная функция ошибки рассмотрены во второй главе. В алгоритме № 1 оба варианта предусматривают совместное обучение калибровочного слоя и классификатора. В комбинированной функции ошибки к перекрёстной энтропии добавляется средний квадрат отклонения скорректированного подтензора от опорного, сформированного по спектру класса. Схема обучаемой нейросетевой калибровки ГСИ представлена на рисунке 4.




Рисунок 4 – Схема обучаемой нейросетевой калибровки ГСИ

В разделе 3.4 исследована коррекция позиционной неоднородности ГСИ (алгоритм № 1). Опорными спектрами служат наиболее яркие спектры классов печатной калибровочной сцены разработанного гиперспектрометра. Коэффициенты переносятся на независимую тестовую сцену без перенастройки. При общей фиксированной спектральной предобработке и нормировании по белому эталону оцениваются профили сигнала вдоль щели и точность классификации. Наибольшая ОА каждого классификатора получена при нейросетевой настройке.

В разделе 3.5 исследована межприборная коррекция по опорным спектрам эталонной ГСА (алгоритм № 2). Настраивается только калибровочный слой; предобработка и классификатор фиксированы. Попиксельное совмещение ГСИ не выполняется. Исходный вариант включает нормирование по белому эталону, остальные – также общую спектральную предобработку. Гребневая регрессия

обеспечила максимальный PSNR и минимальный RMSE, нейросетевая настройка – максимальную точность классификации. В таблице 3 приведены наибольшие средние ОА для каждого классификатора и варианта по результатам экспериментов с алгоритмами № 1 и № 2; F1-мера относится к тем же конфигурациям. Номер алгоритма указывает эксперимент, из которого взят результат, в том числе для базовых вариантов.

Таблица 3 – Лучшие результаты классификации при проверке алгоритмов № 1 и № 2 (средние значения по трём запускам)

Классификатор	Вариант коррекции	Вариант алгоритма	Точность (ОА), %	Взв. F1-мера, %
1DCNN	Без калибровки	2	78,70	75,35
	По белому эталону	1	86,66	86,39
	Обучаемая, перекрёстная энтропия	2	96,78	96,77
NM3DCNN	Без калибровки	1	96,85	96,83
	По белому эталону	1	97,16	97,17
	Обучаемая, перекрёстная энтропия	1	98,73	98,73
SSFTT	Без калибровки	1	97,86	97,36
	По белому эталону	1	98,31	98,00
	Обучаемая, комбинированная функция ошибки	1	98,51	98,51

Показано снижение различий спектров одного класса вдоль щели и ослабление локальных спектральных колебаний (рисунок 5).




Рисунок 5 – Спектры до и после нейросетевой коррекции, один класс калибровочной сцены в трёх положениях вдоль щели




Рисунок 6 – RGB-представления калибровочной сцены и профили сигнала вдоль щелевой диафрагмы без калибровки, после нейросетевой калибровки и калибровки по белому эталону

В разделе 3.6 алгоритм № 1 проверен на данных Specim FX: сравниваются AIE (Automatic Image Enhancement) и AIE с обучаемой коррекцией. Слой настраивается по собственной калибровочной сцене в масштабированных цифровых отсчётах без перевода в коэффициенты спектральной яркости (КСЯ) и фиксируется для двух тестовых сцен; классификаторы обучаются отдельно для каждой сцены. ОА и взвешенная F1-мера повысились в пяти из шести сочетаний сцены и классификатора. Результаты сцены № 2 приведены в таблице 4. Таблица 4 – Результаты классификации тестовой сцены № 2 Specim FX со штатной калибровкой AIE и дополнительной обучаемой коррекцией; средние значения по трём запускам

Классификатор	Specim AIE		Specim AIE с нейросетевой калибровкой		
	ОА, %	Взв. F1-мера, %	Слой	ОА, %	Взв. F1-мера, %
1DCNN	64,09	58,12	pv	70,99	66,74
NM3DCNN	96,67	96,67	pm	97,58	97,59
SSFTT	94,25	94,07	m	95,86	95,83

В разделе 3.7 сформулированы выводы о применении позиционно-зависимой коррекции, переносе фиксированных коэффициентов между сценами и их применении с классификаторами другой архитектуры.

Заключение

В настоящем исследовании предложен показатель качества ГСИ на основе точности классификации в целевой задаче (ТКЦЗ), получено теоретическое и экспериментальное подтверждение его преимущества перед метриками сопоставления с эталонным ГСИ, разработана методика использования ТКЦЗ для повышения точности решения задачи поэлементной классификации. На основе показателя ТКЦЗ разработаны метод и нейросетевые алгоритмы предобработки ГСИ, методика формирования ГСИ, обеспечивающие повышение точности поэлементной классификации. Разработаны нейросетевые алгоритмы позиционно-зависимой коррекции пространственно-спектральных искажений ГСИ с оптимизацией по критерию ТКЦЗ, реализованные в виде калибровочных слоёв, переносимых между различными нейросетевыми классификаторами.

Основные результаты работы заключаются в следующем.

1. Предложенная методика формирования калибровочной сцены для сканирующих гиперспектрометров с оценкой показателя точности классификации в целевой задаче (ТКЦЗ) является более устойчивой к малым пространственным рассогласованиям между ГСИ, чем классические метрики PSNR, SSIM и SAM, основанные на сравнении с эталонным изображением, что подтверждено теоретическими и экспериментальными исследованиями на открытом наборе NTIRE и наборах данных, собранных различными сканирующими гиперспектральными камерами, в том числе камерами Specim IQ и Specim FX.

2. Разработанный нейросетевой алгоритм спектрального сглаживания и коррекции уровня чёрного в ГСИ позволяет повысить точность поэлементной классификации с использованием свёрточных (1DCNN, NM3DCNN) и трансформерных (SSFTT) нейросетевых классификаторов. Прирост точности относительно варианта без дополнительной предобработки составил от 2,17 до 6,22 п.п., прирост взвешенной F1-меры – от 2,03 до 7,68 п.п., а прирост PSNR между средними спектральными векторами классов – от 0,268 до 0,695 дБ. По сравнению с предобработкой на основе фильтра Савицкого–Голея соответствующие приросты составили от 1,25 до 5,19 п.п., от 1,44 до 5,53 п.п. и от 0,187 до 0,614 дБ. По сравнению с нейросетевыми аналогами применение предложенного алгоритма позволило повысить общую точность поэлементной классификации на 0,94–1,45 п.п., а взвешенную F1-меру – на 0,94–1,47 п.п.

3. Разработанная методика выбора параметров формирования ГСИ с оптимизацией по критерию ТКЦЗ позволяет определять усиление камеры, время экспозиции и параметры сжатия. В эксперименте с выбором времени экспозиции и усиления камеры прирост точности поэлементной классификации на тестовой сцене составил 1,81; 0,90 и 2,51 п.п. для 1DCNN, NM3DCNN и SSFTT соответственно.

4. Разработаны алгоритмы обучаемой позиционно-зависимой коррекции ГСИ в виде переносимых калибровочных слоёв. Применение этих слоёв с одномерными (1DCNN) и трёхмерными (NM3DCNN) свёрточными классификаторами, а также трансформерными моделями (SSFTT) обеспечило прирост точности поэлементной классификации от 0,65 до 8,83 п.п. и взвешенной F1-меры от 1,15 до 10,43 п.п. по сравнению с ГСИ без калибровки. По сравнению с калибровкой по белому эталону соответствующие приросты составили от 0,20 до 1,57 п.п. и от 0,51 до 1,56 п.п. На тестовой сцене №2 гиперспектрометра Specim FX по сравнению с данными с AIE применение разработанных алгоритмов обеспечило прирост точности классификации от 0,91 до 6,90 п.п. и взвешенной F1-меры от 0,92 до 8,62 п.п.

Публикации автора по тематике исследования

В изданиях, индексируемых в международных базах цитирования Web of Science и Scopus (1 Q1, 3 Q2, 3 Q3), приравненных к журналам перечня ВАК:

1. **Makarov, A.** Deep Spectral-Spatial Transformer for Robust Hyperspectral Image Segmentation in Varying Field Conditions / A. Makarov, I. Mirpulatov, N. Firsov, V. Lobanov, S. Illarionova, A. Nikonorov, V. Podlipnov, Y. Vybornova, D. Shadrin, A. Rastorguev, R. Skidanov, E. Burnaev // IEEE Access. – 2025. – Vol. 13. **Q1.**

2. Новиков И.А., **Макаров А.Р.**, Подлипнов В.В. и др. Классификация интенсивности цветения водорослей на основе методов машинного обучения и гиперспектральных данных БПЛА // Компьютерная оптика. – 2025. – Т. 49, № 6. – С. 972–985. **Q2.**

3. **Макаров, А.Р.** Нейросетевой метод коррекции пространственно-спектральной чувствительности щелевого гиперспектрометра / А.Р. Макаров, А.В. Никоноров // Компьютерная оптика. – 2025. – Т. 49, № 6. – С. 947–960. – DOI: 10.18287/COJ1812. **Q2**.

4. Фирсов, Н.А. Ансамбли спектрально-пространственных свёрточных нейросетевых моделей для задачи классификации типов почв на гиперспектральных изображениях / Н.А. Фирсов, В.В. Подлипов, Н.А. Ивлиев, Д.Д. Рыськова, А.В. Пирогов, А.А. Музыка, **А.Р. Макаров** [и др.] // Компьютерная оптика. – 2023. – Т. 47, № 5. – С. 795–805. – DOI: 10.18287/2412-6179-CO-1260. **Q2**.

5. Novikov I., **Makarov A.**, Pirogov A. [et al.] Analysis of Hyperspectral Images of River Waters // Optical Memory and Neural Networks (Information Optics). – 2024. – Vol. 33, Suppl. 2. – P. S386–S397. **Q3**.

6. **Makarov, A. R.** Hyperspectral Imaging for Soil Type Classification / **A. R. Makarov**, A. A. Muzyka, K. E. Savelev [et al.] // Optical Memory and Neural Networks (Information Optics). – 2025. – Vol. 34, Suppl. 2. – P. S312–S318. **Q3**.

7. Hamza, M. M. Hyperspectral Camera – Attachment for Microscopy / M. M. Hamza, A. Hamandi, **A. R. Makarov** [et al.] // Journal of Biomedical Photonics & Engineering. – 2021. – Vol. 7, № 3. – Art. 030405. **Q3**

В прочих изданиях, индексируемых в международных базах цитирования Web of Science и Scopus, в т.ч. 3 конференции уровня А*:

8. Pronin A., Vladimirov D., Korepanov A., Muzyka A., **Makarov A.**, Podtikhova S., Ershov E., Rastorguev A., Skidanov R., Nikonorov A. Diffract and Conquer: Hyperspectral Imaging from Any RGB Camera via Optical Encoding and Learning // Proceedings of the Thirty-Fifth International Joint Conference on Artificial Intelligence. – 2026. – P. 1523–1531. **A***.

9. Muzyka, A. Demo Abstract: A Snapshot Hyperspectral Camera Add-On for Real-Time Face Anti-Spoofing / A. Muzyka, **A. Makarov**, A. Pronin [et al.] // Proceedings of the 2026 ACM/IEEE International Conference on Embedded Artificial Intelligence and Sensing Systems – Posters and Demos (SenSys-Adjunct 2026). – 2026. – P. 27–28. **A***.

10. Pronin, A. Poster Abstract: Drop-In Diffractive Hyperspectral Module for Face Anti-Spoofing / A. Pronin, D. Vladimirov, A. Korepanov [et al.] // Proceedings of the 2026 ACM/IEEE International Conference on Embedded Artificial Intelligence and Sensing Systems – Posters and Demos (SenSys-Adjunct 2026). – 2026. – P. 47–48. **A***.

11. Ryskova, D. Neural network classification of soils with different carbon and calcium content based on hyperspectral data / D. Ryskova, A. Nikonorov, A. Pirogov, **A. Makarov** [et al.] // 2023 IX International Conference on Information Technology and Nanotechnology (ITNT). – 2023. – DOI: 10.1109/ITNT57377.2023.10139139.

12. Pirogov, A. Hyperspectral images neural network analysis of unstained micropreparations / A. Pirogov, A. Nikonorov, A. Muzyka, **A. Makarov** [et al.] // 2023 IX International Conference on Information Technology and Nanotechnology (ITNT). – 2023. – DOI: 10.1109/ITNT57377.2023.10139173.

13. **Makarov, A. R.** Neural network classification of coffee varieties on hyperspectral images / **A. R. Makarov**, V. V. Podlipnov, N. A. Ivliev [et al.] // 2022 8th International Conference on Information Technology and Nanotechnology (ITNT). – 2022. – P. 1–3.

Патент на изобретение

14. Патент Российской Федерации на изобретение № 2840891. Метод поиска загрязнений водной поверхности / **А.Р. Макаров**, Д.В. Домбровский, В.В. Подлипов, Н.А. Фирсов, В.Е. Лобанов, А.В. Никоноров, В.И. Платонов, Д.Н. Овакимян, Р.В. Скиданов, О.В. Калашникова. Заявка 23 ноября 2023 г. Опубликовано 23 мая 2025 г.