

Мясников Евгений Валерьевич

**ФОРМИРОВАНИЕ ИНФОРМАТИВНЫХ ПРИЗНАКОВ
ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ
ФУНКЦИЙ РАССТОЯНИЯ**

2.3.8. Информатика и информационные процессы

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
доктора технических наук

Работа выполнена в федеральном государственном автономном образовательном учреждении высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королева» на кафедре геоинформатики и информационной безопасности.

Научный консультант:

доктор технических наук, профессор **Сергеев Владислав Викторович**.

Официальные оппоненты:

Дементьев Виталий Евгеньевич, доктор технических наук, федеральное государственное бюджетное образовательное учреждение высшего образования «Ульяновский государственный технический университет», заведующий кафедрой «Радиотехника, телекоммуникации и защита информации»;

Николаев Дмитрий Петрович, доктор технических наук, федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук», руководитель отдела 95;

Турлапов Вадим Евгеньевич, доктор технических наук, федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского», профессор кафедры высокопроизводительных вычислений и системного программирования.

Ведущая организация:

федеральное государственное бюджетное учреждение науки **Институт космических исследований Российской академии наук**, г. Москва.

Защита состоится 4 декабря 2026 г. в 11.00 часов 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, г. Самара, Московское шоссе, д. 34.

С диссертацией можно ознакомиться в библиотеке федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С. П. Королева» и на официальном сайте по электронному адресу: https://ssau.ru/resources/dis_protection/myasnikov.

Автореферат разослан «__» _____ 2026 г.

Ученый секретарь

диссертационного совета 24.2.379.09,
доктор технических наук, доцент

С. В. Востокин

Общая характеристика работы

Диссертация посвящена разработке методов, алгоритмов и программных средств формирования признаков цифровых гиперспектральных изображений, обеспечивающих повышенное качество решения прикладных задач.

Актуальность темы. Гиперспектральные изображения (ГСИ) представляют собой трехмерные массивы данных, содержащие в себе как пространственную информацию о наблюдаемой сцене, так и детальную спектральную информацию, соответствующую каждой паре дискретных пространственных координат. В привычных для нас цветных изображениях каждый пиксель содержит спектральную информацию, зарегистрированную в трех широких спектральных полосах, соответствующих красному, зеленому и синему каналам. Широко используемые в дистанционном зондировании Земли (ДЗЗ) мультиспектральные изображения содержат большее количество каналов (как правило, от 4 до 16) и могут включать как видимый, так и невидимый для человеческого глаза диапазоны (поддиапазоны инфракрасного, редко ультрафиолетовый диапазон). В отличие от цветных и мультиспектральных изображений, ГСИ регистрируются с гораздо более высоким спектральным разрешением и содержат сотни спектральных каналов.

На сегодняшний день гиперспектральная съемка применяется в самых различных областях человеческой деятельности. Используемая изначально для целей геологии (разведка полезных ископаемых), гиперспектральная съемка успешно применяется в сельском хозяйстве (мониторинг состояния посевов), минералогии (поиск и идентификация минералов), пищевой индустрии (оценка качества продуктов, поиск инородных включений и т.д.), а также химии, медицине, экологии, астрономии и других областях.

Постепенное снижение стоимости и повышение качества гиперспектральных камер, а также неуклонное развитие аппаратных средств, используемых для обработки результатов гиперспектральной съемки, приводят как к росту объемов гиперспектральных данных, так и расширению спектра решаемых с их помощью прикладных задач. Так, например, уже появились публикации, в которых гиперспектральная съемка используется для повышения качества распознавания сцены при автономной навигации.

Развитию аппаратных средств, используемых для регистрации гиперспектральных данных, сопутствует и развитие алгоритмических средств, используемых для обработки и анализа гиперспектральных данных. Развитием этого научного направления занимались научные коллективы как в России, так и за рубежом. Можно выделить целый ряд российских ученых, внесших вклад в развитие указанного научного направления: Зеленцов В.А., Казанский Н.Л., Козодеров В.В., Лупян Е.А., Мясников В.В., Никоноров А.В., Обухова Н.А., Пестунов И.А., Пожар В.Э., Потатуркин О.И., Пяткин В.П., Саворский В.П., Сергеев В.В., Сойфер В.А., Турлапов В.Е., Фурсов В.А., Шилин Б.В. и др. Среди зарубежных ученых можно отметить Benediktsson J.A., Bioucas-Dias J.M., Boardman J.W., Bruzzone L., Camps-Valls G., Chang C.-I., Chanussot J., Fauvel M., Gamba P., Landgrebe D. Mustard J.F., Nascimento J.M.P., Plaza A. и др.

ГСИ имеют ряд особенностей, которые необходимо учитывать при их обработке и анализе. Во-первых, вследствие большого количества регистрируемых спектральных компонент, ГСИ занимают при равном пространственном разрешении гораздо больший объем памяти, чем обычные цветные или мультиспектральные изображения, что обуславливает чрезвычайно высокую стоимость и временные затраты как на передачу и хранение, так и на обработку таких изображений. Во-вторых, *гиперспектральные данные высокоспецифичны*, т.к. различная регистрирующая аппаратура может иметь различное число спектральных каналов, снимать в различных спектральных диапазонах, иметь различное пространственное разрешение и т.п. В-третьих, классы изображенных на сцене объектов часто обладают большой вариативностью – зависимостью их спектральных

характеристик от целого ряда факторов (*спектральная изменчивость*). Например, при анализе растительности влияние на регистрируемые спектральные характеристики оказывают условия освещения, атмосфера, угол съемки, фаза развития, условия роста растений, а в некоторых случаях время суток, погодные условия и т.д.

Другой важный аспект, который необходимо учитывать при анализе ГСИ, связан с семантической разметкой таких данных. Ручная разметка ГСИ является, как правило, трудоемкой и дорогостоящей процедурой, так как связана с необходимостью осуществления наземных измерений (для изображений ДЗЗ), привлечения квалифицированных экспертов для анализа биоматериалов (в медицине) и т.п. Вследствие этого *формируемые обучающие выборки для процедур классификации, как правило, очень ограничены по объему*.

Высокое спектральное разрешение ГСИ приводит к тому, что соседние спектральные диапазоны оказываются очень узкими и сильно коррелированными, что обуславливает, во-первых, *избыточность ГСИ*, а, во-вторых, *высокую размерность спектрального пространства* пикселей ГСИ. Последняя особенность, с учетом ограниченности объемов обучающих выборок, приводит к разреженности спектрального пространства и создает предпосылки для проявления, так называемого, *феномена проклятья размерности*, что может вызывать падение качества работы традиционных методов анализа и классификации, рост вычислительных затрат.

По перечисленным выше причинам при решении задач анализа и классификации ГСИ часто используются не исходные данные, а извлеченная из них признаковая информация. При формировании такой информации, с одной стороны, стараются уменьшить ее избыточность, что позволяет снизить расходы на передачу (в том случае, когда формирование признаков производится до передачи) и хранение данных, а также производить обработку и анализ данных за меньшее время. С другой стороны, к формируемым признакам предъявляют требование информативности, то есть возможности решения прикладных задач с тем же или более высоким качеством по сравнению с исходными гиперспектральными данными. Успешное решение проблемы формирования информативных признаков позволит вместо исходного ГСИ работать со сформированным признаковым представлением, обеспечивающим наилучшие характеристики качества для решения различных прикладных задач обработки и анализа ГСИ (классификации, сегментации, обнаружения аномалий, визуализации и др.), обращаясь к исходным гиперспектральным данным лишь в особых случаях.

Сегодня для анализа ГСИ используется широкий спектр «классических» признаков (спектральные, пространственные и спектрально-пространственные признаки), а также нейросетевые признаки. К сожалению, исходные спектральные признаки сильно избыточны, отдельные спектральные компоненты или их комбинации в виде индексов, эффективно используемые при решении одних задач, часто малоинформативны при решении других. Существенным недостатком спектральных признаков является их неспособность учитывать пространственную информацию ГСИ. Пространственные (текстурные) признаки чаще всего извлекаются из одно- или трехкомпонентных представлений, полученных тем или иным образом из ГСИ. Вследствие этого детальная спектральная информация в таких признаках оказывается утраченной.

Большей информативностью обладают спектрально-пространственные признаки. Часто такие признаки формируются путем объединения богатой спектральной информации, содержащейся в пикселях ГСИ, и локальных пространственных признаков, либо путем извлечения трехмерных участков (патчей) ГСИ. Так как сформированные такими способами признаки имеют еще больший объем, чем сами ГСИ, от исходных ГСИ переходят к их представлениям в виде сегментов или суперпикселей, которые описывают усредненными спектральными и пространственными характеристиками. В таких

описаниях, однако, оказываются утраченными отличия между пикселями внутри сегментов (суперпикселей).

По указанным причинам все большую популярность среди исследователей завоевывают признаки, извлекаемые из ГСИ глубокими нейросетями. В том случае, когда используемые нейросети тем или иным способом адаптированы под конкретный класс ГСИ, такой подход способен учитывать как пространственную, так и богатую спектральную информацию, содержащуюся в ГСИ в их исходном разрешении. Однако необходимость настройки большого количества параметров в нейросетях является фактором, сдерживающим их практическое применение для анализа ГСИ по причине недостаточного объема обучающих выборок. Возможности использования методов переноса обучения (трансферного обучения) в области ГСИ также ограничены из-за высокой специфичности гиперспектральных данных и решаемых задач (в отличие от распространенных задач компьютерного зрения), а также спектральной изменчивости данных. Указанные факторы в совокупности приводят к тому, что получение достаточно универсальных нейросетевых моделей, эффективно учитывающих природу гиперспектральных изображений, на сегодняшний день весьма затруднительно.

Эффективным подходом к формированию информативных признаков ГСИ может стать использование методов снижения размерности. Применение таких методов для формирования информативных признаков позволит устранить не только избыточность гиперспектральных данных, но и предпосылки проявления «проклятия размерности». В подавляющем большинстве случаев при анализе ГСИ используются линейные методы снижения размерности, однако, по мнению автора, более предпочтительным следовало бы считать использование нелинейных методов, так как именно они позволяют учесть нелинейную природу гиперспектральных данных (проявляющуюся вследствие многократных переотражений света в реальных сценах).

Нелинейные методы снижения размерности в своей работе, как правило, опираются на использование евклидовой метрики, однако допускают и возможность использования других функций расстояния. Указанная возможность представляется существенной, так как использование именно неевклидовых расстояний (спектральный угол, дивергенция спектральной информации и др.) представляется при анализе ГСИ более обоснованным с физической точки зрения (например, обеспечивается инвариантность к уровню освещенности), а также часто обеспечивает превосходство перед евклидовой метрикой с точки зрения качества решения прикладных задач.

К сожалению, известные вычислительные процедуры формирования признаков, основанные на нелинейных методах снижения размерности общего назначения, как правило, обладают неприемлемо большим временем работы и пригодны для обработки лишь небольших наборов данных. Кроме того, в них нет естественной возможности учета пространственной информации, содержащейся в изображениях, а также отсутствуют механизмы совмещения (слияния) извлекаемых из ГСИ признаков различной природы. Поэтому разработка методов формирования информативных признаков ГСИ на основе специализированных алгоритмов снижения размерности, позволяющих учесть как различные функции расстояния, используемые при анализе ГСИ, так и содержащуюся в ГСИ пространственную информацию, представляется *возможной и перспективной*.

Исходя из сказанного, **научно-техническая проблема** *вычислительно-эффективного формирования информативных признаков гиперспектральных изображений, позволяющих устранить избыточность (сократить размерность) гиперспектральных данных без потери существенной информации, содержащейся в исходных гиперспектральных изображениях, представляется важной и актуальной.* Решению указанной проблемы и посвящена настоящая диссертация.

Цель и задачи исследования. Целью исследования является разработка методов формирования *информативных признаков гиперспектральных изображений на основе функций расстояния* для повышения эффективности использования гиперспектральных изображений.

Для достижения поставленной цели в диссертации решаются следующие **задачи**:

1. Анализ существующих методов и алгоритмов формирования признаков гиперспектральных изображений.
2. Разработка алгоритмов формирования признаков ГСИ на основе различных функций расстояния, используемых при анализе ГСИ.
3. Разработка методов формирования признаков ГСИ, позволяющих учитывать пространственную информацию, содержащуюся в ГСИ, а также выполнять слияние разнородных признаков.
4. Разработка алгоритмических способов ускорения формирования признаков, а также разработка параллельных реализаций, позволяющих выполнять формирование признаков с использованием современных графических процессоров.
5. Оценка эффективности разработанных методов в прикладных задачах классификации, кластеризации, сегментации и визуализации ГСИ.

Объект исследования – цифровые гиперспектральные изображения.

Предмет исследования – методы формирования признаков, извлекаемых из гиперспектральных изображений.

Методы исследования. В диссертационной работе используются методы машинного обучения и анализа данных, теории вероятностей и математической статистики, методы оптимизации.

Новизна исследования.

1. Разработан комплекс алгоритмических средств формирования признаков ГСИ на основе сохранения попарных расстояний, а именно: спектральных углов, дивергенции спектральной информации, дивергенции Хеллингера, угла Бхаттачария, а также спектральной корреляции.

Предложенные алгоритмы отличаются от известных применением методов снижения размерности гиперспектральных данных с учетом заданных неевклидовых расстояний. Предложенные алгоритмы позволяют формировать на основе содержащейся в ГСИ спектральной информации компактные признаковые представления, обеспечивающие повышенную точность попиксельной классификации.

2. Разработан новый метод формирования признаков ГСИ с учетом локального пространственного контекста на основе порядковых статистик.

Предложенный метод отличается от известных использованием для учета пространственного контекста порядковых статистик, рассчитанных с использованием выбранных функций расстояния в спектральном пространстве пикселей ГСИ. Предложенный метод позволяет формировать на основе пространственно-спектральной информации, содержащейся в ГСИ, компактные признаковые представления, обеспечивающие повышенную точность попиксельной классификации.

3. Разработан новый метод слияния разнородных признаков на основе приведения исходных систем признаков к однородным промежуточным представлениям с последующим объединением этих представлений и снижением размерности; предложены модификации метода для случаев использования пространства с евклидовой метрикой и l_p метрикой для промежуточного представления.

Предложенный метод отличается от известных использованием оригинальной схемы слияния разнородных признаков на основе выбранных функций расстояния, как в пространстве исходных признаков, так и в формируемом пространстве. Метод позволяет формировать на основе заданных систем признаков компактные признаковые

представления ГСИ, обеспечивающие повышенную точность попиксельной классификации.

4. Разработаны новые алгоритмы и численные методы, обеспечивающие ускорение формирования признаков ГСИ, а именно:

- предложены алгоритм построения списка опорных узлов и численный метод ускорения формирования признаков на основе опорных узлов, а также модификация метода, учитывающая характеристики узлов как во входном, так и в формируемом пространствах;

- предложены алгоритм построения очереди опорных узлов с приоритетом и соответствующая модификация метода ускорения формирования признаков на основе очередей с приоритетом;

- предложен комбинированный метод ускорения формирования признаков на основе стохастического градиентного спуска, очередей опорных узлов с приоритетом и алгоритмов многомерной интерполяции.

Предложенные методы отличаются от известных использованием бинарных деревьев для разделения как входного, так и формируемых пространств при снижении размерности гиперспектральных данных, а также использованием очередей с приоритетом для управления вычислительной сложностью. Предложенные методы обеспечивают повышенную производительность формирования признаков.

5. Разработаны программные средства формирования признаков ГСИ с использованием параллельной многопоточной реализации для современных графических процессоров NVIDIA и AMD.

Предложенные алгоритмы и программная реализация отличаются от соответствующих последовательных реализаций повышенной производительностью за счет использования специфики аппаратных средств.

6. Разработаны новые методы и алгоритмы решения некоторых задач анализа ГСИ:

- предложен алгоритм кластеризации, основанный на использовании неевклидовых метрик, в частности, дивергенции Хеллингера и угла Бхаттачария;

- предложен новый метод сегментации ГСИ, основанный на оценке размерности в пространственных областях.

7. Представлены результаты экспериментальных исследований, демонстрирующих преимущества предложенных методов и алгоритмов.

Научное и прикладное значение.

Научная значимость работы состоит в развитии методов неуправляемого анализа многомерных данных, в частности, ГСИ. Предложенные методы и алгоритмы формирования признаков работоспособны при отсутствии априорной информации об информативности исходных признаков, не требуют предварительной разметки данных или обучающих множеств. Полученные в работе результаты в совокупности доказывают, что построение информативных признаков в принципе возможно в рамках неуправляемого подхода, если правильно определить функцию расстояний между экземплярами.

Предложенные во второй главе диссертации алгоритмы формирования признаков и способ их построения, а также предложенный в третьей главе метод слияния разнородных признаков в значительной степени универсальны – их можно распространить на данные других типов (модальностей) в тех случаях, когда различия между экземплярами данных можно измерить с использованием задаваемых пользователем функций расстояния. Предложенный в пятой главе алгоритм кластеризации, основанный на использовании неевклидовых метрик, также может быть распространен на другие метрики или использоваться с многомерными данными других типов.

Разработанные в четвертой главе численные методы, обеспечивающие ускорение формирования признаков, также могут рассматриваться в качестве методов снижения

размерности общего назначения с пониженной (управляемой) вычислительной сложностью и применяться в других областях.

В целом, предложенные методы и алгоритмы формирования признаков расширяют инструментарий анализа ГСИ.

Прикладное значение работы состоит в снижении избыточности исходных гиперспектральных данных с сохранением информативности и без потери пространственного разрешения. Разработанные в диссертации методы и алгоритмы позволяют перейти от исходных ГСИ, содержащих сотни спектральных каналов, к изображениям, состоящим из десятков компонент (признаков) и обеспечивающим ускорение обработки при аналогичных или лучших результатах распознавания.

Разработанные в четвертой главе программные средства формирования признаков ГСИ с использованием параллельной многопоточной реализации позволяют значительно (до нескольких сотен раз) сократить время формирования признаков или снижения размерности по сравнению с однопоточной версией.

Предложенные в работе методы и алгоритмы могут применяться при решении задач классификации гиперспектральных данных дистанционного зондирования, полученных с космических и атмосферных летательных аппаратов, данных наземной гиперспектральной съемки, гиперспектральных данных дорожной обстановки, гиперспектральных медицинских изображений и др., что подтверждается представленными в работе примерами решения актуальных прикладных задач.

Область применения. Результаты исследования применимы в компьютерных системах обработки, анализа и распознавания ГСИ. Наибольший эффект может быть достигнут в тех областях, где уже сегодня широко используется гиперспектральная съемка (сельское хозяйство, дистанционный мониторинг чрезвычайных ситуаций, медицина, пищевая индустрия и др.).

Кроме того, результаты исследования могут быть применимы в научных исследованиях для визуализации многомерных признаков пространств и формирования псевдоцветовых представлений мульти- и гиперспектральных изображений.

Реализация результатов работы. Результаты диссертации использованы при выполнении проектов РФФИ 18-07-01312-а «Методы нелинейного снижения размерности гиперспектральных изображений и их применение», 16-37-00202-мол_а «Разработка методов сегментации мульти- и гиперспектральных цифровых спутниковых снимков с использованием нелинейного отображения с пониженной вычислительной сложностью», 20-37-70053-ст «Методы и алгоритмы обеспечения пассивной защиты цифровых изображений и их последовательностей с использованием внутренней и внешней информации», 18-01-00748-а «Анализ и обработка цифровых изображений с использованием нелинейных отображений, конструируемых с использованием отношений», 16-29-09494-офи_м «Методы компьютерной обработки мультиспектральных данных дистанционного зондирования Земли для определения ареалов растений в специальных криминалистических экспертизах», 09-01-00434-а «Эффективные линейные локальные признаки цифровых сигналов и изображений», 07-07-97603-р_офи «Информационные технологии создания региональной инфраструктуры геопространственных данных», 07-07-97610-р_офи «Разработка фундаментальных принципов синтеза и оптимизации алгоритмов обработки многомерных сигналов/изображений», 07-01-12070-офи «Разработка новых информационных технологий компрессии многомерных сигналов», грантов Министерства образования и науки Самарской области «Анализ мульти- и гиперспектральных космических изображений с использованием нелинейных методов снижения размерности», «Развитие методов анализа гиперспектральных космических изображений с использованием нелинейных методов снижения размерности данных с пониженной вычислительной сложностью», научно-исследовательского проекта «Фундаментальные проблемы

разработки аэрокосмических транспортных систем и управления в аэрокосмической технике для обеспечения связанности территории Российской Федерации» (Соглашение № 075-15-2024-558) в рамках государственной программы Российской Федерации «Научно-технологическое развитие Российской Федерации», а также в ряде хоздоговорных НИР в Самарском университете, АО «Самара-Информспутник», Институте систем обработки изображений РАН — филиале ФНИЦ «Кристаллография и фотоника» РАН (наименования тем указаны в соответствующих актах использования результатов диссертации).

Апробация работы. Основные результаты диссертации были представлены на международных научных конференциях: Image Mining. Theory and Applications – IMTA, проводимая в рамках International Conference on Pattern Recognition - ICPR (Индия, Калькутта, 2024; Монреаль, Канада, 2022; Милан, Италия, 2021), International Workshop on Photogrammetric Data Analysis - ISPRS PDA24 (Москва, Россия, 2024), Международная конференция и молодежная школа «Информационные технологии и нанотехнологии» (Самара, Россия, 2016-2023), Symposium on Intelligent Systems and Telecommunication - IST в рамках SIBIRCON 2022 (2022), Workshop on Hyperspectral Image and Signal Processing, Evolution in Remote Sensing - WHISPERS 2021 (Амстердам, Нидерланды, 2021), Analysis of Images, Social Networks and Texts - AIST (Тбилиси, Грузия, 2021; Москва, Россия, 2017, 2018), International Multi-Conference on Industrial Engineering and Modern Technologies - FarEastCon, (Владивосток, Россия, 2020), International Conference on Machine Vision - ICMV (Амстердам, Нидерланды, 2019; Барселона, Испания, 2015; Ницца, Франция, 2016), International Multi-Conference on Engineering, Computer and Information Sciences – SIBIRCON (Екатеринбург, Россия, 2019), International Conference on Computer Vision and Graphics – ICCVG 2016 (Варшава, Польша, 2016, 2018), International Conference on Image Analysis and Processing - ICIAP 2017 (Катания, Италия, 2017), Computer Analysis of Images and Patterns – CAIP 2017 (Истад, Швеция, 2017), International Conference on Image Analysis and Recognition – ICIAR 2016 (Повоа де варзим, Португалия, 2016), 23rd International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision - WSCG 2015 (Пльзень, Чехия), 9-th Open German-Russian Workshop on Pattern Recognition and Image Understanding – OGRW-2014 (Кобленц, Германия, 2014), International Conference on Pattern Recognition and Image Analysis: New Information Technologies (Санкт-Петербург, Нижний Новгород, Йошкар-Ола, Самара, Россия, 2004-2013), 9-я международная конференция «Интеллектуализация обработки информации» (Будва, Черногория, 2012), 9-ая научная конференция «Электронные библиотеки: перспективные методы и технологии, электронные коллекции» - RCDL'2007, (Переславль-Залесский, Россия, 2007).

Публикации. По теме диссертационной работы автором опубликовано 45 работ, в т.ч. 39 работ в рецензируемых изданиях, индексируемых в базах данных Scopus и Web of Science (WoS), и глава в монографии. 36 работ выполнены без соавторов.

Соответствие паспорту специальности 2.3.8. Информатика и информационные процессы. Область исследования соответствует направлениям исследований паспорта научной специальности 2.3.8 в части пунктов: 3 - Разработка методов и алгоритмов кодирования, сжатия и размещения информации для повышения эффективности и надежности функционирования инфокоммуникационных систем при её хранении и передаче; 4 - Разработка методов и технологий цифровой обработки аудиовизуальной информации с целью обнаружения закономерностей в данных, включая обработку текстовых и иных изображений, видео контента; 7 - Разработка методов обработки, группировки и аннотирования информации, в том числе, извлеченной из сети интернет, для систем поддержки принятия решений, интеллектуального поиска, анализа; 12 - Разработка технологий извлечения и анализа информации в больших базах данных, в том числе, с использованием концепции многомерного представления (OLAP) и интеллектуального анализа данных (Data Mining) статического и в реальном масштабе

времени, реализация моделей баз знаний; 13 - Разработка и применение методов распознавания образов, кластерного анализа, нейросетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных.

Структура диссертации. Диссертация состоит из введения, пяти глав, заключения, списка литературы (366 наименований) и четырех приложений. Работа изложена на 354 страницах, содержит 102 рисунка, 24 таблицы.

На защиту выносятся:

1. Комплекс алгоритмических средств формирования сжатого признакового представления ГСИ на основе сохранения попарных расстояний, а именно: спектральных углов, дивергенции спектральной информации, дивергенции Хеллингера, угла Бхаттачария, а также спектральной корреляции для последующего хранения и анализа.

2. Метод формирования сжатого признакового представления ГСИ с учетом локального пространственного контекста на основе порядковых статистик для последующего хранения и анализа.

3. Метод слияния разнородных признаков на основе приведения исходных систем признаков к однородным промежуточным представлениям с последующим объединением этих представлений и снижением размерности; модификации метода для случаев использования пространства с евклидовой метрикой и l_p метрикой для промежуточного представления разнородной информации.

4. Комплекс алгоритмических средств (численные методы), обеспечивающих ускорение формирования сжатого признакового представления ГСИ и управление вычислительной сложностью и построенных на основе стохастических алгоритмов, интерполяции и разделения входного и формируемого пространств с использованием специальных древовидных структур данных.

5. Комплекс алгоритмических средств (алгоритмы и параллельная программная реализация), выполняющих формирование сжатого признакового представления ГСИ с использованием графических процессоров NVIDIA и AMD.

6. Алгоритм кластеризации (группировки), основанный на использовании неевклидовых метрик, в частности, дивергенции Хеллингера и угла Бхаттачария. Метод сегментации ГСИ, основанный на оценке размерности в пространственных областях.

7. Результаты решения прикладных задач (результаты экспериментальных исследований) обработки и анализа гиперспектральных изображений, подтвердившие эффективность разработанных методов и алгоритмов, а именно:

- классификации (аннотирования) гиперспектральных данных дистанционного зондирования высокого разрешения, полученных с беспилотного летательного аппарата;
- классификации (аннотирования) гиперспектральных данных дорожной обстановки;
- классификации (аннотирования) гиперспектральных изображений мозга человека;
- классификации (аннотирования) растительности по данным наземной гиперспектральной съемки;
- визуализации признаков пространств и формирования псевдоцветовых представлений гиперспектральных изображений.

Краткое содержание диссертации

Первая глава диссертации посвящена анализу современного состояния в области исследований, а также постановке задачи формирования признаков ГСИ на основе функций расстояния.

В главе представлен анализ существующих методов формирования признаков ГСИ. Рассмотрены исходные спектральные признаки (значения яркости в различных спектральных каналах), их комбинации в виде различных индексов (NDVI, NDWI, SAVI и

др.) и производные признаки на основе одномерных преобразований; пространственные признаки, в частности, текстурные признаки (рассчитываемые с использованием матриц совместной встречаемости, фильтров Габора и т.д.); спектрально-пространственные признаки, извлекаемые из трехмерных участков (патчей, гиперкубов), суперпикселей или сегментов исходного изображения, из графовых представлений ГСИ и т.д.; признаки формы (например, морфологические, HOG); нейросетевые признаки, извлекаемые с использованием сверточных (1D-CNN, 2D-CNN, 3D-CNN) моделей, трансформерных и иных архитектур.

Выполнена классификация существующих методов формирования признаков (рисунок 1), отмечены их достоинства и недостатки. Сделаны выводы об избыточности исходных гиперспектральных данных и необходимости формирования компактных признаковых представлений, учитывающих как спектральные, так и пространственные характеристики ГСИ, достаточно универсальных для решения различных прикладных задач анализа ГСИ.



Рисунок 1 – Методы формирования признаков ГСИ

Далее в главе произведен анализ существующих подходов к устранению избыточности ГСИ. В частности, рассмотрены подходы (рисунок 2) на основе сжатия (компрессии) ГСИ, методы на основе моделей спектрального смешивания, нейросетевые методы, методы управляемого отбора спектральных компонент ГСИ, а также методы снижения размерности данных ГСИ. Указано на основные достоинства и недостатки рассмотренных подходов, сделан вывод о целесообразности построения компактных признаковых представлений ГСИ на основе методов снижения размерности.

После этого рассмотрены существующие методы снижения размерности общего назначения, в частности, линейные методы: метод главных компонент (PCA; К. Pearson, Н. Hotelling), метод случайных проекций (Е. Bingham, Н. Mannila), классическое многомерное шкалирование (J. Ramsay), линейные автоассоциативные нейронные сети (AANN; D. Ballard); нелинейные методы снижения размерности, основанные на сохранении общих свойств: отображение Сэммона (J. Sammon Jr.), Isomap (J. Tenenbaum), нелинейные AANN (М. Kramer); а также нелинейные методы снижения размерности, основанные на сохранении локальных свойств: анализ криволинейных компонент (Р. Demartines, J. Hérault), нейронные сети Кохонена (Т. Kohonen), локально-линейное вложение (LLE, S. Roweis, L. Saul), метод лапласианских собственных карт (LE; М. Belkin, Р. Niyogi), метод развертки максимальной дисперсии (К. Weinberger, L. Saul, F. Sha),

метод выравнивания локальных касательных подпространств (Z. Zhang, H. Zha), метод стохастического вложения соседей (G. Hinton, S. Roweis), метод аппроксимации и проекции однородного многообразия (UMAP; L. McInnes, J. Healy, J. Melville), эластичные главные графы (А.Н. Горбань, А.Ю. Зиновьев).

Проведенный анализ позволил выявить следующие недостатки и ограничения

рассмотренных методов снижения размерности для

формирования признаков представлений ГСИ. Во-первых, это отсутствие естественных механизмов учета содержащейся в ГСИ пространственной информации. Во-вторых, методы общего назначения имеют ограниченные возможности работы с неевклидовыми мерами рассогласования, а также комбинирования таких мер или различных систем признаков. В-третьих, работа с ГСИ характеризуется как исключительно большим количеством обрабатываемых объектов (точек, векторов), так и высокими размерностями входных пространств (спектральные пространства, системы с большим количеством признаков). Это делает высокую вычислительную сложность, присущую большинству нелинейных методов снижения размерности общего назначения, препятствием для их применения в анализе ГСИ.

Далее в работе приводится постановка задачи формирования информативных признаков, состоящая в следующем. Пусть дано гиперспектральное изображение $I_X \in \mathbb{R}^{H \times W \times M}$, представляющее собой набор пикселей $X = \{x_1, x_2, \dots, x_N\}$, где H – высота, W – ширина ГСИ, $N = WH$ – количество пикселей, M – количество спектральных каналов (диапазонов) ГСИ, $M \geq 2$. Требуется сформировать изображение $I_Y \in \mathbb{R}^{H \times W \times m}$ того же пространственного разрешения $H \times W$ с пикселями $Y = \{y_1, y_2, \dots, y_N\}$, содержащими меньшее количество компонент $m < M$ (требование компактности), таким образом, чтобы качество решения задач анализа ГСИ по сформированному изображению I_Y было близко к качеству решения таких задач по исходному ГСИ I_X (требование информативности признакового представления) в смысле заданного критерия, исходя из представленных ниже принципов.

1) *Сохранение выбранных расстояний* между отсчетами ГСИ. Значения выбранной функции расстояния d между соответствующими пикселями исходного и формируемого изображений должны по возможности сохраняться: $d(x_i, x_j) \approx d(y_i, y_j)$, $i, j = 1 \dots N$. Иными словами, близкие в спектральном пространстве в смысле выбранной функции расстояния отсчеты исходного ГСИ должны оставаться близкими в формируемом пространстве, а далекие отсчеты – далекими. Это позволит применять в сформированном признаковом пространстве существующие функции расстояния, эффективность которых доказана.

2) *Учет как спектральных, так и пространственных характеристик ГСИ*, а также интеграция спектральной информации ГСИ с другими системами признаков при формировании признаков. Если кроме спектральных признаков $I_X \in \mathbb{R}^{H \times W \times M}$ на вход



Рисунок 2 – Подходы к устранению избыточности ГСИ

процедуре формирования поданы также пространственные признаки $I_X \in \mathbb{R}^{H \times W \times M'}$, выходное изображение $I_Y \in \mathbb{R}^{H \times W \times m}$, $m < M + M'$ должно формироваться на основе признаков обоих типов. Это позволит учитывать в формируемых представлениях пространственные взаимосвязи, содержащиеся в изображениях.

3) При работе с ГСИ, содержащими большое количество отсчетов, должна быть обеспечена возможность разработки *методов с пониженной вычислительной сложностью* и возможностью *управления вычислительной сложностью*, что позволит находить баланс между качеством получаемого решения и скоростью обработки данных.

4) Должна быть обеспечена возможность реализации *методов с использованием параллельных вычислительных сред*, что позволит эффективно использовать современные аппаратные средства для обеспечения высокой скорости обработки данных.

Поставленная описанным образом задача может решаться для любого отдельно взятого ГСИ (набора изображений), что обеспечивает *адаптивность* процедуры формирования к этому изображению (набору).

Представленные выше принципы положены в основу созданных в диссертации методов, определяют задачи диссертационного исследования и структуру диссертационной работы.

Во **второй главе** диссертации разработан комплекс алгоритмических средств формирования признаков ГСИ, основанных на сохранении попарных расстояний.

Предложены алгоритмы, работающие на основе сохранения l_p расстояний (Минковского), спектральных углов (1), дивергенции спектральной информации (2), дивергенции Хеллингера (3), углов Бхаттачария (4), а также спектральной корреляции.

Для построения указанных алгоритмов вводится ошибка ε представления гиперспектральных данных в формируемом пространстве меньшей размерности (5) с использованием требуемой функции расстояния d во входном и выходном пространствах, аналитически определяется градиент $\nabla \varepsilon$ введенного функционала ошибки, после чего производится построение численной процедуры формирования признаков на основе алгоритма градиентного спуска. В выражении (5) μ - масштабный коэффициент, ρ_{ij} - весовые множители.

Полученное решение для l_p расстояний имеет вид:

$$y_{ik}^{[t+1]} = y_{ik}^{[t]} + 2\alpha\mu \sum_{\substack{j=1, \\ j \neq i}}^N \rho_{ij} \frac{\|x_i - x_j\|_p - \|y_i^{[t]} - y_j^{[t]}\|_p}{\|y_i^{[t]} - y_j^{[t]}\|_p^{p-1}} |y_{ik}^{[t]} - y_{jk}^{[t]}|^{p-1} \operatorname{sgn}(y_{ik}^{[t]} - y_{jk}^{[t]}). \quad (6)$$

Соответствующий алгоритм формирования признаков для $p=2$ (евклидова расстояния) далее будем обозначать как EDPM. В этом и последующих выражениях (7)-(11) $y_{ik}^{[t]}$ означает k -ю компоненту i -го пикселя в формируемом пространстве на шаге t , где $i=1 \dots N$, $k=1 \dots m$. В работе отмечается, что в частных случаях функционал ошибки (5) сводится к

известным ошибкам, используемым в многомерном шкалировании и отображении Сэммона.

Для случая использования *спектральных углов* получено решение (SAPM) в декартовых координатах

$$y_{ik}^{[t+1]} = y_{ik}^{[t]} - 2\alpha\mu \sum_{\substack{j=1, \\ j \neq i}}^N \rho_{ij} \left(\theta(x_i, x_j) - \theta(y_i^{[t]}, y_j^{[t]}) \right) \frac{y_{jk}^{[t]} - y_{ik}^{[t]} \langle y_i^{[t]}, y_j^{[t]} \rangle}{\sqrt{1 - \langle y_i^{[t]}, y_j^{[t]} \rangle^2}} \quad (7)$$

и гиперсферических координатах, а также альтернативное решение, основанное на модифицированной мере рассогласования углов. При этом отмечается, что в контексте рассматриваемого алгоритма преобразование данных к гиперсферическим координатам позволяет дополнительно снизить размерность выходного пространства на единицу, так как отображение на гиперсферу в L – мерном пространстве может рассматриваться как отображение в $(L - 1)$ – мерное выходное пространство.

Решение для *спектральной корреляции corr* (в отличие от функций расстояния является мерой подобия) выглядит следующим образом (SCPM):

$$y_{ik}^{[t+1]} = y_{ik}^{[t]} - 2\alpha\mu \sum_{\substack{j=1, \\ j \neq i}}^N \rho_{ij} \frac{\text{corr}(x_i, x_j) - \text{corr}(y_i^{[t]}, y_j^{[t]})}{g_{ij}^{[t]}} \left(my_{jk}^{[t]} - \sum_{l=1}^m y_{jl}^{[t]} - \left(my_{ik}^{[t]} - \sum_{l=1}^m y_{il}^{[t]} \right) f_{ij}^{[t]} \right), \quad (8)$$

где $f_{ij} = \frac{m \sum_{k=1}^m y_{ik} y_{jk} - \sum_{k=1}^m y_{ik} \sum_{k=1}^m y_{jk}}{m \sum_{k=1}^m y_{ik}^2 - \left(\sum_{k=1}^m y_{ik} \right)^2},$

$$g_{ij} = \sqrt{m \sum_{k=1}^m y_{ik}^2 - \left(\sum_{k=1}^m y_{ik} \right)^2} \sqrt{m \sum_{k=1}^m y_{jk}^2 - \left(\sum_{k=1}^m y_{jk} \right)^2}.$$

Для *дивергенции спектральной информации* (2) рекуррентное соотношение, позволяющее уточнять координаты векторов в редуцированном спектральном пространстве, имеет вид (SDPM):

$$y_{ik}^{[t+1]} = y_{ik}^{[t]} + \frac{2\alpha\mu}{\sum_{l=1}^m y_{il}^{[t]}} \sum_{\substack{j=1, \\ j \neq i}}^N \rho_{ij} \left(\text{SID}(x_i, x_j) - \text{SID}(y_i^{[t]}, y_j^{[t]}) \right) \left(1 - \frac{p_k(y_j^{[t]})}{p_k(y_i^{[t]})} + \log \frac{p_k(y_i^{[t]})}{p_k(y_j^{[t]})} - D(y_i^{[t]} \| y_j^{[t]}) \right). \quad (9)$$

В работе отмечено, что при реализации градиентной процедуры оптимизации для дивергенции спектральной информации хорошие результаты достигаются с использованием экспоненциального градиентного спуска.

Решения для *дивергенции Хеллингера* (3) и *угла Бхаттачария* (4) приведены в выражениях (10) и (11):

$$y_{ik}^{[t+1]} = y_{ik}^{[t]} + \frac{\alpha\mu}{2 \sum_{l=1}^m y_{il}^{[t]}} \sum_{\substack{j=1, \\ j \neq i}}^N \rho_{ij} \frac{\text{HD}(x_i, x_j) - \text{HD}(y_i^{[t]}, y_j^{[t]})}{\text{HD}(y_i^{[t]}, y_j^{[t]})} \left(\sum_{l=1}^m \sqrt{p_l(y_i^{[t]}) p_l(y_j^{[t]})} - \sqrt{\frac{p_k(y_j^{[t]})}{p_k(y_i^{[t]})}} \right), \quad (10)$$

$$y_{ik}^{[t+1]} = y_{ik}^{[t]} + \frac{\alpha\mu}{\sum_{l=1}^m y_{il}^{[t]}} \sum_{\substack{j=1, \\ j \neq i}}^N \rho_{ij} \frac{\text{BCa}(x_i, x_j) - \text{BCa}(y_i^{[t]}, y_j^{[t]})}{\sqrt{1 - \left(\sum_{l=1}^m \sqrt{p_l(y_i^{[t]}) p_l(y_j^{[t]})} \right)^2}} \left(\sum_{l=1}^m \sqrt{p_l(y_i^{[t]}) p_l(y_j^{[t]})} - \sqrt{\frac{p_k(y_j^{[t]})}{p_k(y_i^{[t]})}} \right). \quad (11)$$

Далее соответствующие алгоритмы будем называть HDPM и BCSPM.

Другим рассмотренным подходом к использованию неевклидовых расстояний при формировании признаков стала *аппроксимация заданных расстояний во входном пространстве евклидовыми расстояниями в выходном формируемом пространстве*. Во второй главе диссертации указанный подход реализован со всеми приведенными выше

функциями расстояния (1-4) в виде алгоритмов, основанных на спектральных углах (SAED), дивергенции Хеллингера (HDED), углах Бхаттачария (BCED) и др.

Выполнено исследование разработанных алгоритмов формирования признаков ГСИ, основанных на сохранении заданных расстояний (6-11). Показано, что предложенные алгоритмы позволяют успешно снизить ошибку (5) представления данных ГСИ в формируемом пространстве сниженной размерности, а также обладают преимуществами перед альтернативными методами в смысле качества попиксельной классификации данных ГСИ на основе формируемых компактных представлений ГСИ. В качестве альтернатив в исследовании рассматривались линейный метод главных компонент (PCA) и ряд альтернативных нелинейных методов, основанных на методах снижения размерности общего назначения (Isomap, LLE, LE, UMAP) в комбинации с различными функциями расстояния.

Для проведения описанных в главе 2 экспериментов использовались открытые гиперспектральные сцены Indian pines, Salinas, Pavia University, Botswana, Kennedy Space Center (KSC). Для оценки качества работы исследуемых методов использовалась точность классификации отсчетов указанных ГСИ классификатором по ближайшему соседу (NN). Указанный простейший классификатор не имеет параметров и не требует предварительного обучения, что исключает возможные нюансы при сравнении, связанные с неоптимальностью его настройки. В таблице 1 показаны алгоритмы формирования признаков ГСИ, обеспечивающие лучшие результаты классификации на каждой из сцен для различных размерностей m формируемого пространства. Видно, что предложенные алгоритмы формирования, основанные на сохранении заданных расстояний (помечены темно-серым цветом), а также основанные на аппроксимации заданных расстояний во входном пространстве евклидовыми расстояниями в формируемом пространстве (помечены светло-серым цветом), показали себя лучше альтернативных при размерностях $m=5..15$ и выше. При размерности $m \geq 10$ с использованием разработанных алгоритмов удалось превзойти качество классификации по исходным данным в 70% случаев, независимо от используемой функции расстояния (соответствующие ячейки в таблице выделены жирным). Для сравнения в последней строке «Исходные» показано наивысшее качество классификации, полученное по исходным данным с использованием всех рассмотренных функций расстояния, а также количество каналов в соответствующих ГСИ.

Таблица 1 – Качество классификации ГСИ по сформированным представлениям. Результат сформирован в виде: «метод формирования признаков: точность классификации (%)»

m	Тестовое ГСИ				
	Indian Pines	Salinas	Botswana	Pavia Univ.	KSC
2	UMAP-SAM: 70,1%	UMAP-ED: 86,1%	UMAP-SAM: 90,9%	UMAP-ED: 77,1%	UMAP-SAM: 87,3%
3	UMAP-SID: 70,8%	UMAP-ED: 86,2%	UMAP-SAM: 90,9%	UMAP-ED: 77,4%	UMAP-SAM: 88,2%
5	SAED:72,4%	HDED:87,2%	SAED:93,9%	EDPM:81,3%	UMAP-SAM:88,6%
10	SDPM:80,1%	HDED:89,1%	HDED:93,8%	EDPM:85,0%	UMAP-SAM:88,1%
15	SDPM:82,1%	HDED:89,4%	HDPM:93,9%	EDPM:84,9%	SAPM:88,7%
20	SDPM:82,3%	BCED:89,3%	HDPM:94,1%	EDPM:89,4%	SAED:89,8%
25	SDPM:81,0%	HDED:89,2%	BCED:94,3%	EDPM:85,2%	SAED:92,0%
30	SDPM:80,2%	HDED:89,7%	HDPM:93,8%	EDPM:84,2%	SAED:90,9%
35	SDPM:82,5%	BCED:89,2%	BCED:94,6%	EDPM:84,5%	HDED:90,8%
40	SDPM:82,7%	BCPM:88,6%	HDPM:94,5%	EDPM:85,3%	SAPM:91,1%
Исход- ные	77,5% ($M=200$)	88,6% ($M=204$)	94,4% ($M=145$)	84,6% ($M=103$)	90,3% ($M=176$)

В третьей главе диссертации рассматриваются способы учета пространственной информации, содержащейся в ГСИ, и возможности интеграции различных систем признаков. Основная идея внедрения пространственного контекста при формировании признаков состоит в аппроксимации расстояний, построенных на основе пространственного контекста пикселей ГСИ, евклидовыми расстояниями в формируемом пространстве с последующим снижением размерности. В рамках диссертационного исследования исследуются две схемы реализации этой идеи.

Первая из схем состоит в использовании широко распространенного механизма расширения пространства признаков значениями пикселей из окрестности некоторого радиуса с последующим построением функции расстояния, учитывающей значения этих пикселей. Значения пикселей в расширенном пространстве берутся с коэффициентами, определяемыми с использованием

двумерных радиально-симметричных оконных функций в качестве весовых функций. Функция расстояния $\tilde{d}$ между двумя «расширенными» пикселями $\tilde{x}_i$ и $\tilde{x}_j$, построенная с учетом K -пиксельного соседства, содержащего соответственно

$$\tilde{d}(\tilde{x}_i, \tilde{x}_j) = \left(\sum_{k=1}^K w_k \sum_{l=1}^M (x_{i_k l} - x_{j_k l})^2 \right)^{1/2} \quad (12)$$

точки $x_{i_1}, x_{i_2}, \dots, x_{i_K}$ и $x_{j_1}, x_{j_2}, \dots, x_{j_K}$, выражается в виде (12). В этом выражении каждый весовой коэффициент w_k определяется значением функции $w(r)$, аргумент r которой является евклидовым расстоянием на плоскости изображения между пикселем x_i и k -м пикселем из его окрестности: $w_k = w(r(x_i, x_{i_k}))$. В качестве оконных функций рассмотрено семейство вида (13), графики показаны на рисунке 3.

$$w(r) = \begin{cases} 1 - (r/R)^p, & \text{если } (r \in [0; R]) \text{ и } (p > 0), \\ (1 - r/R)^{-p}, & \text{если } (r \in [0; R]) \text{ и } (p < 0), \\ 0, & \text{иначе.} \end{cases} \quad (13)$$




Рисунок 3 – Функции окна

Во второй схеме, реализованной в виде метода формирования признаков ГСИ с учетом локального пространственного контекста на основе порядковых статистик, используется адаптивное взвешивание, основанное на сходстве пикселей в окрестности. При реализации этой схемы пиксели $x_{i_1}, x_{i_2}, \dots, x_{i_K}$ из пространственной окрестности пикселя x_i сортируются по близости к центральному пикселю в смысле выбранного базового расстояния d : $d(x_i, x_{(i_1)}) \leq d(x_i, x_{(i_2)}) \leq \dots \leq d(x_i, x_{(i_K)})$.

Далее усеченные переупорядоченные наборы пикселей, представляющие собой первые S порядковых статистик $x_{(i_1)}, x_{(i_2)}, \dots, x_{(i_S)}$, $S \leq K$, используются для определения функции расстояния $\tilde{d}$ между отсчетами изображения:

$$\tilde{d}(x_i, x_j) = \eta \sum_{s=1}^S \frac{1}{S} d(x_{(i_s)}, x_{(j_s)}). \quad (14)$$

Здесь η - масштабный коэффициент. Представленная схема позволяет учитывать пространственный контекст, причем работает адаптивно, назначая веса пикселям пространственной окрестности в зависимости от их характеристик.

В работе проведено исследование двух описанных схем учета пространственного контекста. Указывается на важность выбора способа разбиения данных на обучающую и тестовые выборки и исследуется два способа разбиения – случайное разбиение и фиксированное разбиение, при котором классифицированные области разбиваются на

обучающее и тестовое множества ортогонально оси, вдоль которой область является наиболее вытянутой. Отмечается, что случайное разбиение дает переоцененные показатели качества вследствие взаимного проникновения информации из обучающей и тестовой выборок при использовании пространственного контекста, т.е. оценки качества при случайном разбиении оказываются завышенными.

Было показано, что с использованием оконных функций для учета пространственного контекста удалось получить прирост качества классификации на 4,5-16,1% по сравнению с версией без использования пространственного контекста при использовании случайного разбиения на обучающие и тестовые выборки. В то же время при использовании фиксированного разбиения прирост качества оказался менее значительным и стабильным – до 2,3%, что подтверждает важность выбора способа формирования обучающей и тестовой выборок.

Использование метода на основе порядковых статистик обеспечило не только прирост качества по сравнению с базовой версией без использования пространственного контекста (на 3,3-9,1%), но и преимущество по сравнению с методом на основе оконных функций при использовании фиксированного разбиения (на 1,2%-6,3%). Кроме того, метод на основе порядковых статистик позволил использовать неевклидовы расстояния. В рамках главы были рассмотрены две такие функции расстояния – спектральный угол и дивергенция Хеллингера. При использовании спектральных углов прирост качества составил 6,1%-12,5% для случайного разбиения и 3,2%-7,1% для фиксированного разбиения. При использовании дивергенции Хеллингера – 5,8-13,0% и 3,2-7,3% для случайного и фиксированного разбиений соответственно. Примеры зависимости точности классификации от параметров двух рассмотренных методов учета пространственного контекста показаны на рисунке 4.




Рисунок 4 - Зависимость точности классификации Acc от параметра p функции окна (13) для метода учета пространственного контекста на основе оконных функций (а). Зависимость точности классификации Acc от параметра S функции расстояния (14) для метода учета пространственного контекста на основе порядковых статистик, использующего евклидовы расстояния (б), спектральные углы (в), дивергенцию Хеллингера (г).

Размерность формируемого пространства $m=15$, радиус соседства $R=3$

Одним из центральных результатов главы является *метод слияния разнородных признаков*. Сложность задачи слияния признаков может быть обусловлена отсутствием явной связи между системами признаков, их несовместимостью (например, признаки переменной и фиксированной размерности), слишком высокой размерностью

результатирующего пространства при простой конкатенации, необходимостью использования разных метрик или мер схожести для сопоставления объектов, существенно разной размерностью систем признаков и другими причинами.

Предложенный в работе метод слияния признаков основан на приведении исходных систем признаков к однородным (в смысле свойств соответствующих пространств) промежуточным представлениям с последующим слиянием этих представлений и снижением размерности (рисунок 5).

В работе показано, что при использовании пространства с евклидовой метрикой для промежуточного представления данных, расстояния в объединенном пространстве могут рассчитываться в соответствии с выражением (15):

$$d(z_i, z_j) = \left(\sum_{k=1}^{\tilde{M}+\tilde{K}} (z_{ik} - z_{jk})^2 \right)^{1/2} = \left(\lambda_X^2 \varphi^2(x_i, x_j) + \lambda_Y^2 \psi^2(y_i, y_j) \right)^{1/2}, \quad (15)$$

где $\varphi(x_i, x_j)$ и $\psi(y_i, y_j)$ – расстояния между точками $x_i, x_j \in X$ и $y_i, y_j \in Y$ в исходных пространствах $X \subset R^M$ и $Y \subset R^K$, λ_X и λ_Y – масштабные коэффициенты для нормализации с использованием линейного преобразования, $\tilde{M}$ и $\tilde{K}$ – размерности пространств $\tilde{X} \subset R^{\tilde{M}}$ и $\tilde{Y} \subset R^{\tilde{K}}$ для промежуточного представления данных, $z_i, z_j \in Z$ – координаты точек в объединенном пространстве, $d()$ – расстояние в объединенном пространстве.



Рисунок 5 - Схема слияния систем признаков

Таким образом, для случая промежуточных представлений с евклидовой метрикой расчет попарных расстояний на этапе снижения размерности может быть выполнен по (15), минуя явное преобразование исходных данных во внутреннюю форму представления, связанные с этим вычислительные затраты и погрешности.

Аналогичные результаты (16, 17) были получены для более широкого класса l_p метрик и метрики l^∞ :

$$d(z_i, z_j) = \left(\sum_{k=1}^{\tilde{M}+\tilde{K}} (z_{ik} - z_{jk})^p \right)^{1/p} = \left(\lambda_X^p \varphi^p(x_i, x_j) + \lambda_Y^p \psi^p(y_i, y_j) \right)^{1/p}, \quad (16)$$

$$d(z_i, z_j) = \max_{k=1}^{\tilde{M}+\tilde{K}} |z_{ik} - z_{jk}| = \max(\lambda_X \varphi(x_i, x_j), \lambda_Y \psi(y_i, y_j)). \quad (17)$$

Работоспособность предложенного подхода продемонстрирована в работе на примере слияния спектральных признаков, рассогласование между которыми измерялось с использованием евклидова расстояния, спектрального угла и дивергенции Хеллингера, и текстурных признаков, полученных на основе матрицы совместной встречаемости пикселей. Некоторые результаты экспериментов приведены на рисунке 6.




Рисунок 6 - Зависимость точности классификации Acc от относительного масштабного коэффициента λ при слиянии спектральных и текстурных признаков с использованием различных функций расстояния: спектральный угол в спектральном пространстве и евклидово расстояние в текстурном пространстве с классификатором по ближайшему соседу (а) и SVM классификатором (б); дивергенция Хеллингера в спектральном пространстве и евклидово расстояние в текстурном пространстве с классификатором по ближайшему соседу (в)

Предложенный метод слияния признаков применен в работе также для слияния признаков, извлеченных глубокими нейросетями («глубоких» признаков), со спектральными признаками ГСИ (рисунок 7). Показана возможность использования полностью обученной нейронной сети, предназначенной для анализа цветных изображений ДЗЗ (сеть ResNet18, входящая в состав пакета TorchGeo), со спектральными признаками ГСИ.

Предложенная схема не требует какого-либо обучения, кроме подбора размера пространственного окна для извлечения «глубоких» признаков, размерности формируемого пространства и коэффициента слияния.

Некоторые результаты исследований описываемой схемы приведены в Таблице 2. Во всех случаях был получен прирост качества классификации, составляющий в зависимости от тестового ГСИ и используемой функции расстояния 1,2-20,0%.



Рисунок 7 - Схема слияния спектральных признаков с признаками, извлеченными глубокими нейросетями

Таблица 2 – Точность классификации ГСИ по сформированным признакам, полученным в результате слияния «глубоких» и спектральных признаков (фиксированное разбиение)

ГСИ	«Глубокие» признаки	Спектральные признаки			Слияние признаков			Прирост относитель- но «глубоких» / спек- тральных признаков
		ED	SAM	HD	ED	SAM	HD	
Indian Pines	63,5%	64,7%	65,8%	65,8%	82,8%	83,5%	83,2%	19,3-20,0% / 17,0-18,0%
Salinas	84,0%	85,9%	86,4%	87,0%	87,3%	88,0%	88,2%	3,3-4,2% / 1,2-1,5%
Pavia university	76,7%	84,7%	82,8%	81,3%	92,7%	91,3%	90,8%	14,2-16,1% / 7,9-9,5%
KSC	96,5%	86,6%	87,9%	88,3%	98,0%	98,2%	98,2%	1,5-1,7% / 9,9-11,4%

В четвертой главе диссертации разрабатываются алгоритмические способы ускорения предложенных в предыдущих главах методов и алгоритмов формирования признаков. Рассматриваются как известные способы повышения вычислительной эффективности общего назначения, такие как алгоритмы стохастического градиентного спуска и алгоритмы интерполяции, так и оригинальные методы, основанные на разбиении пространства признаков.

При использовании алгоритма градиентного спуска, лежащего в основе рассмотренных ранее методов и алгоритмов формирования признаков, рекуррентное соотношение для координат точек (пикселей) в формируемом пространстве можно записать в обобщенном виде:

$$y_i^{[t+1]} = y_i^{[t]} + 2\alpha\mu \sum_{j=1}^N \zeta(x_i, x_j, y_i^{[t]}, y_j^{[t]}), \quad (18)$$

где $\zeta()$ – функция расчета частичных приращений координат точки i в формируемом пространстве при «взаимодействии» с точкой j . Вид функции ζ определяется конкретным функционалом ошибки (5).

При некоторых упрощениях можно принять оценку вычислительной сложности процедур снижения размерности $O(IN^2(SM+m))$, где I – количество итераций, N – количество точек данных (пикселей ГСИ), S – размер пространственного контекста ($S = 1$, если пространственный контекст не учитывается), M – размерность входного, m – выходного (формируемого) пространства.

Для повышения вычислительной эффективности алгоритма градиентного спуска рассматривались алгоритмы стохастического градиентного спуска: алгоритм аппроксимации градиента на основе небольших подмножеств случайно выбранных точек – мини-выборок (SGD), метод моментов (Momentum) и метод адаптивного градиента (AdaGrad). Некоторые результаты показаны на рисунке 8.




Рисунок 8 - Зависимость ошибки представления гиперспектральных данных в формируемом пространстве ε от номера итерации Iter для ГСИ: Cuprite (а), Indian Pines (б)

Отметим, что приемлемое качество решения задачи с использованием любого из рассмотренных стохастических алгоритмов было получено за время, сравнимое со временем выполнения всего лишь одной итерации базового метода (GD).

Другим рассмотренным в работе способом повышения вычислительной эффективности стало использование алгоритмов интерполяции. При использовании таких алгоритмов мы отображаем K точек данных из исходного пространства в формируемое, используя базовый подход, а затем последовательно отображаем оставшиеся $(N-K)$ точек данных, используя один из алгоритмов многомерной интерполяции. В работе рассмотрено несколько таких алгоритмов, включая интерполяцию по ближайшему соседу (NN), алгоритм взвешенных обратных расстояний (IDW), использование радиальных базисных функций (RBF) и интерполяцию путем минимизации ошибки отображения данных (ErM).

Анализ показал, что время работы алгоритмов интерполяции NN и IDW может быть оценено, как $O(K)$ операций на одну интерполируемую точку. В алгоритме RBF одна

интерполяция требует $O(K)$ операций. Кроме того, требуется $O(K^3)$ операций для определения весов радиальных функций путем решения системы линейных уравнений. Интерполяция путем итеративной минимизации ошибки отображения требует $O(TK)$ операций на одну интерполируемую точку, где T – число итераций. Некоторые численные оценки качества и времени интерполяции для различных алгоритмов приведены на рисунке 9.




Рисунок 9 – Зависимость ошибки представления гиперспектральных данных в формируемом пространстве (сверху) и времени интерполяции (внизу) от количества точек K , отображенных с использованием базового подхода, для различных алгоритмов интерполяции: текстурные признаки (а), спектральные признаки (б)

Радиально-базисные функции и интерполяция путем минимизации ошибки обеспечивают достаточно малые значения ошибки по сравнению с методом ближайшего соседа и интерполяцией IDW. В некоторых случаях при малом количестве базовых точек ($K=100$) RBF интерполяция превосходит интерполяцию путем минимизации ошибки. При больших значениях K предпочтение следует отдавать интерполяции путем минимизации ошибки. В то же время последний алгоритм был существенно более медленным в связи с его итеративной природой. Так, когда количество базовых и добавляемых точек было большим, полное время работы было почти таким же, как для алгоритма стохастического градиентного спуска. Интерполяция радиально-базисными функциями производилась существенно быстрее.

Для ускорения вычислений с использованием *разбиения пространства* все множество точек (пикселей) X разбивается на некоторые подмножества $c_1, c_2, \dots, c_C$ так, чтобы все точки $x_i \in c_j, i=1..|c_j|$ из подмножеств c_j обладали схожими характеристиками. То есть, чтобы все точки из некоторого подмножества c_j находились близко друг к другу в признаковом пространстве. В этом случае при определенных условиях точки подмножества c_j могут рассматриваться не по отдельности, а в совокупности как единый объект.

Предположим, что подмножество c находится «достаточно далеко» от некоторой точки x_i в признаковом пространстве. В этом случае прямая сумма

$$\sum_{x_j \in c} \rho_{ij} \frac{d(x_i, x_j) - d(y_i, y_j)}{d(y_i, y_j)} (y_i - y_j) \quad (19)$$

может быть аппроксимирована следующим образом

$$|c| \rho_{ic} \frac{d(x_i, x_c) - d(y_i, y_c)}{d(y_i, y_c)} (y_i - y_c) \quad (20)$$

где $|c|$ - количество точек в рассматриваемом подмножестве c , $d(x_i, x_c)$ - расстояние от точки x_i до центра подмножества c во входном пространстве, $d(y_i, y_c)$ - расстояние от точки y_i до центра подмножества в формируемом пространстве, x_c, y_c - координаты центра множества точек c во входном и формируемом пространствах соответственно, ρ_{ic} - константы.

Если все точки исходного множества X разделены на C непересекающихся подмножеств, то (18) принимает вид:

$$y_i^{[t+1]} = y_i^{[t]} + 2\alpha\mu \sum_{j=1}^C \tilde{\zeta}(x_i, y_i^{[t]}, c_j), \quad (21)$$

$$\tilde{\zeta}(x_i, y_i^{[t]}, c_j) = |c_j| \rho_{i,c_j} \frac{d(x_i, x_{c_j}) - d(y_i^{[t]}, y_{c_j}^{[t]})}{d(y_i^{[t]}, y_{c_j}^{[t]})} (y_i^{[t]} - y_{c_j}^{[t]}). \quad (22)$$

Очевидно, что выражение (21) позволяет аппроксимировать (18) с некоторой точностью, которая зависит от того, насколько хорошо точки разделены на подмножества.

Для сокращения временных затрат при формировании признаков предложен *метод ускорения формирования признаков на основе опорных узлов*, состоящий из следующих этапов:

1. Разбиение входного пространства;
2. Построение списков опорных узлов;
3. Инициализация в формируемом пространстве;
4. Итеративная оптимизация.

На первом этапе метода ускорения с использованием некоторого алгоритма разбиения пространства (алгоритмы иерархической кластеризации; неиерархические алгоритмы, запускаемые в рекурсивном порядке; алгоритмы построения деревьев бинарного разбиения пространства — BSPT, таких как kd-деревья, vp-деревья, ball-деревья) мы получаем древовидную иерархическую структуру. Корнем структуры является узел верхнего уровня c^0 , а каждая вершина-узел c_i^l на уровне $l > 0$ содержит либо дочерние узлы $\left\{ c_{i_1}^{l+1}, c_{i_2}^{l+1}, \dots, c_{i_{|c_i^l|}}^{l+1} \right\}$, либо непосредственно точки $\left\{ x_{i_1}, x_{i_2}, \dots, x_{i_{|c_i^l|}} \right\}$ исходного множества X в качестве терминальных узлов.

Так как разбиение происходит в исходном пространстве высокой размерности, то дерево декомпозиции остается постоянным на протяжении процесса оптимизации. В работе было предложено предварительно вычислять и хранить множество узлов и точек, используемых в оптимизационном процессе, в виде *списков опорных узлов* для каждой из точек x_i исходного множества. Такие списки формируются на втором этапе метода ускорения. Их использование требует дополнительной памяти, но позволяет избежать повторных вычислений значений критерия разбиения во время оптимизационного процесса и позволяет сохранять предварительно вычисленные расстояния до опорных узлов, что позволяет сделать оптимизационный процесс независимым от размерности входного пространства.

Пусть x - некоторая точка, для которой требуется сформировать список Λ опорных узлов, c_i^l - произвольный узел иерархии. Тогда рассмотренные выше принципы могут быть реализованы в виде следующего рекурсивного *алгоритма построения списка опорных узлов*, используемого на втором этапе метода ускорения.

1. Если узел c_i^l удовлетворяет критерию декомпозиции по отношению к рассматриваемой точке $\Theta(c_i^l, x) = True$ и в c_i^l содержатся дочерние узлы $\left\{c_{i_1}^{l+1}, c_{i_2}^{l+1}, \dots, c_{i_{|c_i^l|}}^{l+1}\right\}$, то применить этот рекурсивный алгоритм для каждого из дочерних узлов $c_{i_1}^{l+1}, c_{i_2}^{l+1}, \dots, c_{i_{|c_i^l|}}^{l+1}$.

2. Если узел c_i^l удовлетворяет критерию декомпозиции по отношению к рассматриваемой точке $\Theta(c_i^l, x) = True$ и в c_i^l содержатся точки $\left\{x_{i_1}, x_{i_2}, \dots, x_{i_{|c_i^l|}}\right\}$, то добавить в список опорных узлов Λ содержащиеся в узле точки: $\Lambda = \Lambda \cup \left\{x_{i_1}, x_{i_2}, \dots, x_{i_{|c_i^l|}}\right\}$.

3. Если узел c_i^l не удовлетворяет критерию декомпозиции по отношению к рассматриваемой точке $\Theta(c_i^l, x) = False$, то добавить его в список опорных узлов: $\Lambda = \Lambda \cup \{c_i^l\}$.

Рассмотренный алгоритм построения списка опорных узлов задан с точностью до функции Θ , определяющей отделимость узла c_i^l от точки x .

На третьем этапе метода ускорения выполняется инициализация координат точек в формируемом пространстве малой размерности с использованием PCA путем проекции координат входного многомерного пространства в подпространство, образуемое первыми m главными компонентами.

Четвертый этап метода ускорения (оптимизация) выполняется с использованием аппроксимации (21) где функция $\tilde{\zeta}(x_i, y_i^{[t]}, n)$ принимает различный вид в зависимости от того, является ли элемент списка опорных узлов n точкой или узлом дерева:

1) если n является точкой x_j , то $\tilde{\zeta}(x_i, y_i^{[t]}, n) = \zeta(x_i, x_j, y_i^{[t]}, y_j^{[t]})$,

а при использовании евклидовых расстояний

$$\tilde{\zeta}(x_i, y_i^{[t]}, n) = \rho_{ij} \frac{d(x_i, x_j) - d(y_i^{[t]}, y_j^{[t]})}{d(y_i^{[t]}, y_j^{[t]})} \cdot (y_i^{[t]} - y_j^{[t]});$$

2) если n является узлом c_j , то $\tilde{\zeta}(x_i, y_i^{[t]}, n) = |c_j| \zeta(x_i, x_{c_j}, y_i^{[t]}, y_{c_j}^{[t]})$,

а при использовании евклидовых расстояний

$$\tilde{\zeta}(x_i, y_i^{[t]}, n) = |c_j| \rho_{i, c_j} \frac{d(x_i, x_{c_j}) - d(y_i^{[t]}, y_{c_j}^{[t]})}{d(y_i^{[t]}, y_{c_j}^{[t]})} \cdot (y_i^{[t]} - y_{c_j}^{[t]}).$$

Вычислительная сложность этапа оптимизации при условии предварительного расчета расстояний во входном пространстве может оцениваться как $O(INLm)$, где L – средняя длина списков опорных узлов.

Особое внимание в работе уделяется вопросу выбора наилучшей структуры для разбиения пространства. В частности, рассмотрены kd-дерево, vr-дерево, и бинарное дерево кластеров, построенное с использованием упрощенного минимаксного алгоритма кластеризации. Было показано, что итоговое качество, измеряемое ошибкой представления гиперспектральных данных в формируемом пространстве ε , слабо зависит от типа разбиющей пространство структуры. В то же время от типа структуры зависит средняя длина списка опорных узлов (которая оказывалась заметно выше при использовании kd-

дерева), а значит, и время, затрачиваемое на построение списка и каждую итерацию оптимизационного процесса.

Еще одним вопросом, затронутым в работе, стал выбор пространства, в котором осуществляется разбиение. С одной стороны, необходимо учитывать конфигурацию точек данных как во входном, так и в формируемом пространстве, чтобы контролировать ошибку аппроксимации, поскольку аппроксимируются расстояния в обоих пространствах. С другой стороны, мы имеем дело с методом формирования, основанном на принципе сохранения попарных расстояний между точками. Поэтому если некоторое подмножество достаточно компактно в многомерном входном пространстве, хотелось бы надеяться на то, что точки в формируемом пространстве низкой размерности данных также будут располагаться достаточно компактно, и ошибки аппроксимации расстояний в формируемом пространстве не будут слишком велики.

В работе помимо метода ускорения, основанного на разбиении исходного пространства, исследовался подход, основанный на разбиении формируемого пространства, а также подход к разбиению, позволяющий учитывать характеристики узлов как во входном, так и в формируемом пространстве.

Отмечено, что разбиение формируемого пространства ведет к необходимости периодического обновления или перестройки той структуры, с использованием которой выполняется разбиение. Причина этого заключается в изменении координат точек в формируемом пространстве по мере выполнения оптимизационного процесса. Сам *метод ускорения формирования признаков с использованием разбиения формируемого пространства* состоит из следующих этапов.

1. Инициализация положения точек в формируемом пространстве малой размерности.
2. Построение KD-дерева для разбиения формируемого пространства.
3. Выполнение очередного шага итеративной процедуры оптимизации, заключающегося в уточнении выходных координат всех точек. При этом для каждой конкретной точки исходного множества для аппроксимации берутся только те узлы дерева, которые достаточно удалены (хорошо отделены) от рассматриваемой точки в формируемом пространстве. Для узлов с истинным значением критерия декомпозиции, выполняется переход к дочерним узлам дерева.
4. Если положение точек в выходном пространстве стабилизировалось, то алгоритм завершает работу, иначе – переход к шагу 2.

Сравнение методов, основанных на разбиении входного (Input space) и формируемого (Output space) пространств, представлено на рисунке 10.

Поскольку хотелось бы не только снизить ошибку аппроксимации, но и избежать повторного перестроения структуры разбиения на каждом шаге, в работе предложена *модификация метода ускорения формирования признаков на основе опорных узлов, учитывающая характеристики узлов как во входном, так и в формируемом пространстве*. В предложенной модификации, как и ранее, по построенной во входном пространстве структуре производится построение списков, содержащих ссылки на узлы структуры разбиения. При этом на этапе оптимизации элементы списка используются непосредственно только тогда, когда соответствующие узлы хорошо отделены от




Рисунок 10 - Зависимость ошибки аппроксимации (а) и ошибки представления данных в формируемом пространстве (б) от количества узлов, участвующих в аппроксимации

рассматриваемой точки также и в формируемом пространстве. В случае же если критерий декомпозиции в формируемом пространстве выполняется, проверяются на соответствие критерию уже дочерние узлы структуры разбиения.

При оценке эффективности такого подхода учитывалась как ошибка аппроксимации, так и влияние на конечную ошибку представления данных в формируемом пространстве. Некоторые результаты экспериментов для различных параметров T_2 критерия декомпозиции в выходном пространстве представлены на рисунке 11 в сравнении с базовым методом ускорения на основе опорных узлов (Input space).




Рисунок 11 - Зависимость ошибки аппроксимации от количества узлов, участвующих в аппроксимации

Несмотря на видимую разницу в ошибке аппроксимации, влияние критерия декомпозиции в выходном пространстве на конечную ошибку представления данных в формируемом пространстве не было значительным и составило в зависимости от набора данных 0,2-0,6%.

Для управления вычислительной сложностью при использовании метода ускорения формирования признаков на основе опорных узлов в работе предложено использовать очереди с приоритетом. Основная идея состоит в том, чтобы использовать меру отделимости точки от узла в качестве приоритета в очереди, так чтобы наиболее плохо отделенные узлы были первыми, а за ними следовали узлы, которые отделены лучше. Алгоритм построения очереди с приоритетом начинается с единственного узла (корня дерева разбиения пространства), после чего следует декомпозиция первого элемента (наиболее плохо отделенного) до тех пор, пока длина очереди не станет равной предварительно определенному значению.

Некоторые результаты экспериментов с предложенным методом ускорения на основе очередей с приоритетом показаны на рисунке 12 в сравнении со стохастическим градиентным спуском. Как показывают результаты, ошибка представления многомерных данных ε для метода ускорения на основе очередей с приоритетом превышает таковую для градиентного спуска лишь при малой длине очередей. После определенной длины, составившей в эксперименте 1% от общего числа точек N , разница становится неотличимой. Время выполнения процесса оптимизации растет с длиной очереди линейно, при этом метод ускорения на основе очередей с приоритетом (Priority queue) выигрывает по скорости вследствие предварительного расчета расстояний в многомерном пространстве.




Рисунок 12 - Зависимость ошибки представления данных в формируемом пространстве ε (а) и среднего времени выполнения одной итерации (б) от доли L/N элементов, используемых в аппроксимации

Следует отметить, что большинство рассмотренных в главе методов и алгоритмов допускают естественное распараллеливание. Так, обновление координат точек данных в алгоритмах градиентного и стохастического градиентного спуска на каждой итерации может осуществляться одновременно. Интерполяция точек также может выполняться

независимо и параллельно. Кроме того, библиотеки cuSOLVER и cuBLAS, включенные в состав инструментария CUDA, позволяют решать системы линейных уравнений с использованием графических процессоров, что значительно ускоряет интерполяцию радиально-базисными функциями.

Общая схема комбинированного метода ускорения формирования признаков на основе описанных в главе методов и алгоритмов представлена на рисунке 13. Необязательные элементы показаны пунктирной линией, альтернативные шаги показаны штрихпунктирной линией.




Рисунок 13 - Схема комбинированного метода

Результаты экспериментов для возможных частных конфигураций приведенной выше схемы представлены на рисунке 14. Эксперименты выполнены на гиперспектральном изображении Indian Pines. Выходная размерность при формировании была установлена равной 3 (3D отображение). Для экспериментов использовался ПК на основе центрального процессора (CPU) Intel Core i7-6500U с тактовой частотой 2.5GHz.

Все результаты относятся к реализации на CPU для обеспечения возможности сравнения. Как можно видеть, наилучшие значения качества представления гиперспектральных данных в формируемом пространстве были получены с использованием стохастического градиентного спуска (SGD) и метода на основе очередей с приоритетом (PQ). При работе с небольшими фрагментами или изображениями, а также в тех случаях, когда возможно использовать высокопроизводительное оборудование, имеет смысл избегать интерполяции (SGD+RBF) по причине падения качества.




Рисунок 14 - Экспериментальные результаты для различных конфигураций: ошибка представления данных в формируемом пространстве (а) и время формирования (б) для ГСИ Indian Pines

Отдельный раздел четвертой главы диссертации посвящен разработке *параллельных реализаций, позволяющих выполнять формирование признаков ГСИ с использованием современных графических процессоров*. Основное внимание уделено разработке на основе архитектуры CUDA для графических процессоров (GPU) NVIDIA. Программная реализация выполнялась на языке C++, широко использовался механизм шаблонов C++.

Важную роль в эффективности подобных решений играют вопросы взаимодействия с памятью. В работе были предложены и исследовались несколько способов организации такого взаимодействия:

1. Базовая реализация алгоритма для GPU с использованием CUDA (NORMAL).

2. Модификация с комбинированной блочно-столбцовой схемой организации памяти для хранения на GPU исходных данных ГСИ высокой размерности (COMB). Схема организации памяти приведена на рисунке 15(а).
3. Модификация, реализующая аналогичную схему организации памяти также для формируемых признаков (COMBY).
4. Модификация, реализующая копирование исходных данных в разделяемую (shared) память GPU (SHARED_X).
5. Модификация, реализующая работу с вектором градиентов в разделяемой памяти GPU (SHARED_Y).
6. Модификация с комбинированной блочно-столбцовой схемой организации памяти для хранения исходных данных на GPU, копированием случайной подвыборки (batch) с построчным распределением данных на GPU и несимметричной реализацией функции расстояния (ASSYM). Модификация показана на рисунке 15(б).
7. Модификация с применением блочно-столбцовой схемы организации памяти (рисунок 15(а)), размещением вектора градиента в разделяемой памяти GPU и разворачиванием циклов (SHARED_Y UNWRAP).




Рисунок 15 - Организация данных: комбинированная блочно-столбцовая схема организации (а); комбинация блочно-столбцовой схемы организации памяти с классической построчной организацией (б)

Некоторые результаты с оценками времени выполнения показаны на рисунке 16. В работе отмечается, что все предложенные модификации показали лучшие результаты по сравнению с базовым методом. Наибольший эффект наблюдался от комбинированной блочно-столбцовой схемы организации памяти для хранения исходных данных, которая легла в основу всех остальных модификаций. Наибольший прирост производительности при размерностях входного пространства 50...500 показала модификация, построенная на базе комбинированной схемы организации памяти, размещении вектора градиента в разделяемой памяти GPU и использующая разворачивание циклов. В Таблице 3 показан коэффициент ускорения при использовании GPU, определяемый как отношение времени

выполнения одной итерации на графическом процессоре ко времени выполнения итерации на CPU, работающем в однопоточном режиме.




Рисунок 16 – Зависимость времени выполнения одной итерации процесса оптимизации (в миллисекундах) от размерности входного пространства для различных GPU: NVIDIA RTX 2070 (а,б), NVIDIA GTX 1070 (в), NVIDIA RTX 3090 (г)

Таблица 3 – Коэффициент ускорения при использовании GPU (NVIDIA RTX 2070 / RTX 3090) относительно CPU (Ryzen 5 5600) в однопоточном режиме

Число точек	Размерность, m				
	1000	500	200	100	50
50000	68,1/144,9	82,2/169,3	243,6/304,5	134,4/336	79,4/198,5
100000	63,4/152,6	95/196	243,1/486,2	149,2/335,8	87,8/197,5
200000	65,8/163,3	94,6/192,2	264,1/480,1	158,1/383,9	93/225,9
500000	63,5/158	95,3/199,8	275,9/490,4	168,6/381,6	91,9/219,6
1000000	62,8/155,5	95,8/201	279,6/506,5	168,3/391,2	99,5/228,7
2000000	-	109,1/229,4	276,3/512,3	170,6/391,9	99,6/231,9
5000000	-	-	310,7/596,7	171,1/406,3	99,6/235,9

Альтернативная реализация методов формирования выполнялась с использованием HIP (Heterogeneous Compute Interface for Portability - интерфейс гетерогенных вычислений для обеспечения переносимости кода) для графических процессоров AMD. Многопоточная реализация для центрального процессора была выполнена на языке C++ с использованием OpenMP. При этом компилятором выполнялась автоматическая векторизация циклов, и использовались инструкции AVX. Использование графического процессора AMD Radeon RX Vega 56, содержащего 3584 потоковых процессора, позволило существенно ускорить решение по сравнению с многопоточной реализацией для центрального процессора AMD Ryzen 7 3700X с базовой частотой 3,6 ГГц. Версия для GPU оказалась более чем в 6 раз быстрее версии для CPU, работающей в 16 потоковом режиме.

В пятой главе диссертационной работы выполнена оценка эффективности разработанных методов и алгоритмов формирования признаков ГСИ в различных прикладных задачах.

При решении задачи классификации гиперспектральных данных дистанционного зондирования высокого разрешения, полученных с беспилотного летательного аппарата, предложенная в главе 3 схема слияния признаков применялась к ГСИ высокого пространственного разрешения (до 4,3 см), полученным с помощью датчика Nano-Hyperspec и входящим в набор Ухань WHU-Hi. В рамках экспериментов исследовалось, как качество классификации менялось в зависимости от выходной размерности и коэффициента слияния «глубоких» и спектральных признаков (см. рисунок 17).

Для сопоставления с альтернативными методами классификации простейший NN-классификатор был заменен на полносвязную сеть (многослойный перцептрон), была определена глубина сети и ширина слоя. Полученные результаты сопоставлялись со следующими альтернативными методами классификации: спектрально-пространственная сеть внимания (spectral-spatial attention network - SSAN), машина опорных векторов (Support Vector Machine - SVM), спектрально-пространственная полносвёрточная сеть (Spectral Spatial Fully Convolutional Network - SSFCN), классификатор на основе условных случайных полей и опорных векторов с ограничением по расстоянию Махаланобиса (Support Vector conditional Random Fields classifier with a Mahalanobis distance boundary Constraint - SVRFMC), подход на основе эволюции объектно-ориентированной фрактальной сети (Object Oriented Fractal Net Evolution Approach - FNEA-OO), глубокие пирамидальные остаточные сети (deep Pyramidal Residual Networks - pResNet), архитектура классификации на основе CNN и CRF (CNN and CRF classification framework - CNNCRF), спектрально-пространственная остаточная сеть (spectral-spatial residual network - SSRN) и архитектура быстрого глобального обучения без использования патчей (Fast Patch-Free Global Learning Framework - FPGA).




Рисунок 17 – Зависимость точности классификации Acc от размерности dim сформированного пространства (а) и коэффициента слияния α для ГСИ WHU-Hi-LongKou (б) и Hi-HanChuan (в)

Результаты для указанных альтернатив были взяты из литературы и получены с использованием точно такого же набора данных с тем же разделением обучающей и тестовой выборок. В результате сопоставления (Таблица 4) показано, что предложенный подход на ГСИ WHU-Hi-LongKou позволил получить хорошее качество классификации, сопоставимое с текущим мировым уровнем и уступающее лучшему результату всего на

0,6%. На изображении WHU-Hi-HongHu метод уступал четырем методам (CNNCRF, SSFCN, pResNet и FPGA), опережая по качеству пять других альтернатив.

Таблица 4 – Сравнение с альтернативными методами на наборе данных WHU-Hi (альтернативные методы, показавшие более низкое качество классификации по сравнению с предложенным, показаны серым цветом)

ГСИ WHU-Hi	Метод									
	SVM	FNEA- OO	SVRFMC	SSAN	SSFCN	SSRN	pResNet	CNNCRF	FPGA	Proposed
LongKou	95,0%	98,6%	98,4%	94,4%	94,6%	99,0%	98,7%	98,9%	99,2%	98,6%
HanChuan	77,6%	85,6%	86,5%	88,6%	89,8%	89,8%	93,3%	93,9%	97,8%	95,4%
HongHu	73,6%	88,8%	89,9%	87,3%	94,3%	91,3%	95,3%	93,7%	97,5%	92,5%

На ГСИ WHU-Hi-HanChuan предложенный метод оказался вторым по качеству методом среди десяти рассмотренных, уступив лишь методу FPGA. При этом классификация в предложенном подходе выполнялась по компактным признаковым представлениям ГСИ в пространстве размерности 30, а для формирования такого представления не требовалось обучение или тонкая настройка глубокой нейросети извлечения признаков. Необходимо было лишь выбрать размерность представления и коэффициент слияния, а для классификации обучить перцептрон, содержащий два скрытых слоя по 1000 нейронов.

При решении задачи классификации гиперспектральных данных дорожной обстановки рассматривались входные данные из набора НуКо, полученные с сенсоров двух типов: гиперспектрального сенсора видимого диапазона и гиперспектрального сенсора ближнего инфракрасного диапазона (рисунок 18).

Первый этап обработки включал в себя переход к суперпиксельному представлению, для чего рассматривались методы на основе многомерного и векторного градиента, а также методы разбиения на суперпиксели для цветных изображений, запускаемые по данным в сниженной размерности. На втором этапе для суперпикселей рассчитывались текстурные признаки (двух типов) и усредненные спектральные признаки. Далее производилось формирование признаков с использованием разработанного метода слияния разнородных признаков. После этого производилось обучение и тестирование классификатора. Примеры данных и некоторые результаты исследования показаны на рисунке 18.

В работе также исследовалась эффективность применения разработанных методов для идентификации опухолей головного мозга по гиперспектральной съемке. Данные для исследования представляли собой 826 каналные гиперспектральные изображения, полученные во время проведения хирургических операций в рамках проекта HELICoID (пример на рисунке 19(a)).

При исследовании на сокращенном наборе данных отмечалось, что использованные текстурные признаки не оказывали заметного положительного влияния на качество классификации (рисунок 19(б)). При этом наибольший положительный эффект был достигнут с использованием метода формирования признаков с учетом локального пространственного контекста на основе порядковых статистик (рисунок 19(в)).

При трехкратной перекрестной проверке (кросс-валидации) на полном множестве данных метод на основе порядковых статистик показал точность классификации $Acc=99,8\%$. Аналогичных результатов удалось достичь и при точном подборе коэффициента слияния ($\lambda=0,96$) текстурных и спектральных признаков. Полученная точность оказалась на 1,4% выше лучших результатов, полученных с использованием PCA

и семи альтернативных классификаторов, рассмотренных в исследовании, что соответствует снижению ошибки классификации в 8 раз.






Рисунок 18 – Примеры сцен из набора НуКо (показана первая главная компонента, изображение контрастировано): видимый диапазон (а, б), ближний инфракрасный диапазон (в). Зависимость качества классификации от коэффициента слияния текстурных и спектральных признаков: для различных расстояний в спектральном пространстве (г), для различных наборов текстурных признаков (д), для данных в ближнем инфракрасном диапазоне (е)

В главе 5 также рассмотрен другой важный класс гиперспектральных изображений, получаемых по результатам наземной гиперспектральной съемки растительности. Этот тип ГСИ наиболее часто применяется при решении сельскохозяйственных задач. Данные, на основе которых проведено исследование, были получены с использованием щелевого гиперспектрометра, построенного по схеме Оффнера, и включали изображения двух зерновых сельхозкультур (овес и кукуруза), сорной травы и неклассифицированные области.


В исследовании было показано, что с использованием стандартного подхода на основе метода главных компонент и классификатора на основе евклидовых расстояний удастся достичь лишь 91,7% точности в пространстве размерности 10 и 94,1% точности в пространстве размерности 20, в то время как разработанный алгоритм формирования признаков, действующий по принципу сохранения спектральных углов, позволяет повысить точность на 4,0% и 2,1% соответственно, что обеспечивает снижение общей ошибки классификации в 1,9 и 1,6 раза соответственно.



(a)



(б)



(в)

Рисунок 19 – Пример изображения мозга человека (а). Зависимость точности классификации от коэффициента слияния текстурных и спектральных признаков для различных мер рассогласования (б). Зависимость точности классификации от количества порядковых статистик (размера пространственного контекста) для различных расстояний во входном пространстве (в)

Помимо демонстрации эффективности изложенных в предыдущих главах подходов при решении задач классификации рассмотрен также ряд других важных задач анализа ГСИ. В частности, рассмотрена задача кластеризации данных с использованием неевклидовых расстояний. Предложены *алгоритмы кластеризации, основанные на использовании дивергенции Хеллингера и угла Бхаттачария*. Предложенные алгоритмы состоят из следующих шагов:

Шаг 1. Разделение точек на кластеры C_i с использованием дивергенции Хеллингера (или угла Бхаттачария) (23).

$$C_i = \left\{ x \mid i = \arg \min_j HD(x, c_j) \right\} \quad (23)$$

Шаг 2. Обновление центроидов кластеров: центроид c кластера C ищется как точка в пространстве, для которой суммарное расстояние до остальных точек кластера минимально в смысле выбранной метрики

$$c = \arg \min_{c^*} \sum_{x \in C} HD^2(x, c^*) \quad (24)$$

(см. выражение (24)). Для этого выполняются следующие шаги:

Шаг 2.a. Инициализация центроида значением $c^{[0]}$.

Шаг 2.b. Итеративное обновление центроида c в соответствии с выражением (для дивергенции Хеллингера):

$$c_k^{[t]} = c_k^{[t-1]} - \frac{\alpha}{2 \sum_{l=1}^M c_l^{[t-1]}} \sum_{x \in C} \left(\sum_{l=1}^M \sqrt{p_l(c^{[t-1]})} p_l(x) - \sqrt{\frac{p_k(x)}{p_k(c^{[t-1]})}} \right), \quad (25)$$

где $c_k^{[t]}$ – k -я компонента центроида c на шаге t .

В качестве альтернативы в работе рассматривался алгоритм k -медоидов (k -medoids), основанный на алгоритме TRIMED, модифицированный для работы с дивергенцией Хеллингера (3). Результат такого сравнения показан на рисунке 20. Как видно из приведенного рисунка, предложенный алгоритм кластеризации (Proposed) обеспечивает существенно лучшие результаты в смысле показателя качества (26).

$$E = \sum_{i=1}^K \sum_{x \in C_i} HD^2(x, c_i) \quad (26)$$




Рисунок 20 - Зависимость качества кластеризации E от количества итераций t

В главе 5 предложен метод сегментации ГСИ, основанный на оценке размерности в пространственных областях. В основу подхода положена идея о том, что добавление пикселей, содержащих новые сигнатуры (например, красный пиксель на рисунке 21), в однородную область неизбежно ведет к увеличению ее внутренней размерности, что используется в работе для построения соответствующего метода (рисунок 22(а)).

Порог t , используемый в методе для оценки размерности, а также размер локальной окрестности являются настройками метода. В работе проведено исследование качества сегментации в зависимости от настроек на основе индекса Рэнда RI (рисунок 22 (г)) и глобальной ошибки согласованности GCE (рисунок 22(д)).

Сравнение с классическими подходами к сегментации гиперспектральных изображений показало преимущество предложенного метода по RI : 0,9821 против 0,942 и 0,9275 для методов, основанных на кластеризации и преобразовании водораздела соответственно при ограничении $GCE < 0,15$.

В пятой главе диссертационной работы также рассмотрены вопросы визуализации на основе методов формирования признаков. В частности, рассмотрен вопрос визуализации признаков пространств гиперспектральных изображений на основе спектральных, текстурных признаков и признаков, полученных в результате слияния.

При этом для измерения рассогласования в указанных пространствах могут использоваться различные функции расстояния.

Также рассматривается задача формирования псевдоцветовых представлений мульти- и гиперспектральных изображений. Отличительной особенностью таких представлений является то, что различия между цветами отсчетов в таких представлениях аппроксимируют выбранные расстояния в многомерных признаковых пространствах ГСИ. Ввиду значительного объема визуального материала, в автореферате приводится лишь один пример (рисунок 23).



Рисунок 21 – Рост размерности в локальной окрестности





Рисунок 22 – Сегментация на основе оценки размерности в пространственных областях: схема метода (а); истинная тематическая классификация (б) и примеры сегментации для различного порога (в); зависимость качества сегментации от порога t (%), используемого для оценки размерности: RI , большие значения лучше (г) и GCE , меньшие значения лучше (д)




Рисунок 23 – 3D-визуализация спектрального пространства изображения Salinas (а). Представление ГСИ Salinas в псевдоцветах (б)

Заключение

В диссертационной работе разработаны методы, алгоритмы и программные средства вычислительно эффективного адаптивного формирования информативных признаков цифровых гиперспектральных изображений на основе функций расстояния, обеспечивающих повышенное качество решения прикладных задач.

В работе были получены следующие основные результаты:

1. Разработан комплекс алгоритмических средств формирования информативных признаков ГСИ, основанных на принципе сохранения попарных расстояний, а именно: спектральных углов, дивергенции спектральной информации, дивергенции Хеллингера,

угла Бхаттачария, а также спектральной корреляции. Предложенные методы позволили существенно сократить размерность гиперспектральных данных (до размерности 10...40), обеспечив лучшее качество классификации по сравнению с альтернативными методами. Кроме того, качество классификации по сформированным признакам оказалось выше качества классификации по исходным данным в более чем 70% случаев.

2. Разработан метод формирования информативных признаков ГСИ с учетом локального пространственного контекста на основе порядковых статистик. Предложенный метод обеспечил прирост качества на 3,3-9,1% по сравнению с базовой версией без пространственного контекста, а также на 1,2% – 6,3% по сравнению с методом на основе оконных функций (при использовании фиксированного разбиения). Кроме того, метод позволил использовать неевклидовы расстояния, обеспечив прирост качества на 3,2-7,3%.

3. Разработан метод слияния разнородных признаков на основе приведения исходных систем признаков к однородным промежуточным представлениям с последующим объединением этих представлений и снижением размерности. Предложенный метод позволил получить прирост качества классификации на 1,2-20% по сравнению с «глубокими» и спектральными признаками.

4. Разработаны новые алгоритмы и численные методы, обеспечивающие ускорение формирования признаков ГСИ, а именно: алгоритм построения списка опорных узлов и численный метод ускорения формирования признаков на основе опорных узлов, а также модификация метода, учитывающая характеристики узлов как во входном, так и в формируемом пространствах; алгоритм построения очереди опорных узлов с приоритетом и соответствующая модификация метода ускорения формирования признаков на основе очередей с приоритетом.

Предложен комбинированный метод ускорения формирования признаков на основе стохастического градиентного спуска, очередей опорных узлов с приоритетом и алгоритмов многомерной интерполяции.

Предложенные методы отличаются от известных повышенной производительностью. В частности, предложенный метод на основе очередей с приоритетом позволяет пользователю выбирать между качеством и скоростью обработки. Показано значительное сокращение времени обработки по сравнению с алгоритмом стохастического градиентного спуска без потери качества.

5. Разработаны программные средства формирования признаков ГСИ с использованием параллельной многопоточной реализации для современных графических процессоров NVIDIA и AMD. При использовании графического процессора NVIDIA RTX 3090 достигнуто ускорение от 145 до 597 раз по сравнению с однопоточной версией, работающей на центральном процессоре.

6. Разработан алгоритм кластеризации гиперспектральных данных при использовании неевклидовых метрик, а также метод сегментации гиперспектральных изображений на основе оценки размерности в пространственных областях.

Получены решения следующих прикладных задач анализа ГСИ: классификация гиперспектральных данных дистанционного зондирования высокого разрешения, полученных с беспилотного летательного аппарата; классификация гиперспектральных данных дорожной обстановки; классификация гиперспектральных изображений мозга человека; классификация растительности по данным наземной гиперспектральной съемки; визуализация признаков пространств; формирование псевдоцветовых представлений ГСИ.

По мнению автора, полученные результаты в совокупности представляют собой решение научной проблемы, являющееся вкладом в развитие информационно-технологической отрасли России. Предложенное в диссертации целостное решение для адаптивного признакового описания гиперспектральных данных позволяет не только устранить избыточность таких данных, но и повысить точность решения прикладных

задач, а также существенно сократить вычислительные затраты. Центральным результатом работы является доказательство эффективности перехода от стандартных евклидовых метрик и глобальных линейных преобразований к неевклидовым функциям расстояния в сочетании с локальным пространственным контекстом. Это обеспечивает стабильный прирост качества на широком спектре прикладных задач: от анализа данных дистанционного зондирования до обработки медицинских гиперспектральных изображений.

Основные публикации по теме диссертации

Глава в монографии:

1. Myasnikov, E.V. Nonlinear Mapping of Hyperspectral Data / E.V. Myasnikov // Series on Language Processing, Pattern Recognition, and Intelligent Systems. Image Analysis and Pattern Recognition. State of the Art in the Russian Federation - 2025. - Vol. 7. – Chapter 9. – P. 363–389.

Статьи в изданиях, индексируемых реферативными базами данных WoS / Scopus:

2. Myasnikov, E. Generation of Compact Representations of Hyperspectral Images Using Neural Network and Spectral Features / E. Myasnikov // ICPR 2024 International Workshops and Challenges. Lecture Notes in Computer Science. - 2025. – Vol. 15616. – P. 274–284.

3. Firsov, N. HyperKAN: Kolmogorov-Arnold Networks make Hyperspectral Image Classifiers Smarter / N. Firsov, E. Myasnikov, V. Lobanov [и др.] // Sensors. – 2024. – Vol. 24(23). – P. 7683.

4. Myasnikov, E.V. Compact representations of hyperspectral images based on the fusion of neural network and spectral features / E.V. Myasnikov // Pattern Recognition and Image Analysis. – 2024. – Vol. 34(4). – P. 1021-1025.

5. Myasnikov, E. Fusion of Deep Learning-based and Spectral Features for Hyperspectral Image Analysis / E.V. Myasnikov // International workshop on Photogrammetric Data Analysis - ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. – 2024. – Vol. X-2/W1-2024. – P. 31–38.

6. Myasnikov, E. A Framework for Feature Fusion with Application to Hyperspectral Images / E. Myasnikov // Lecture Notes in Computer Science. – 2023. - Vol. 13644. - P. 509–518.

7. Myasnikov, E.V. A feature fusion technique for dimensionality reduction / E.V. Myasnikov // Pattern Recognition and Image Analysis. - 2022. - Vol. 32(3). - P. 607-610.

8. Myasnikov, E. Data Dimensionality Reduction Technique Based on Preservation of Hellinger Divergence / E. Myasnikov // Lecture Notes in Computer Science. – 2022. - Vol. 13217. - P. 190-198.

9. Myasnikov, E.V. Comparison of Spectral Dissimilarity Measures and Dimension Reduction Techniques for Hyperspectral Images / E. Myasnikov // Pattern Recognition and Image Analysis. - 2021. –Vol. 31(3). - P. 453–464.

10. Myasnikov, E. Evaluation of spectral similarity measures and dimensionality reduction techniques for hyperspectral images / E. Myasnikov // Lecture Notes in Computer Science. – 2021. Vol. 12665. – P. 289–300.

11. Myasnikov, E. Hyperspectral Data Clustering Using Hellinger Divergence / E. Myasnikov // Journal of Physics: Conference Series. – 2021. - Vol. 2096(1). – P. 012170.

12. Myasnikov, E. Nonlinear dimensionality reduction of hyperspectral data based on spectral information divergence preserving principle / E. Myasnikov // Journal of Physics: Conference Series. - 2019. – Vol. 1368(3). - P. 032030.

13. Myasnikov, E. Nonlinear dimensionality reduction of hyperspectral images based on spectral angles and exploiting the spatial context / E. Myasnikov // Journal of Physics: Conference Series. — 2018. — Vol. 1096(1). – P. 012037.

14. Myasnikov, E. Embedding spatial context into spectral angle based nonlinear mapping for hyperspectral image analysis / E. Myasnikov // Lecture Notes in Computer Science. — 2018. — Vol. 11114. — P. 263-274.
15. Myasnikov, E. Nonlinear dimensionality reduction of hyperspectral data using spectral correlation as a similarity measure / E. Myasnikov // Lecture Notes in Computer Science. — 2018. — Vol. 10716. — P. 237-244.
16. Myasnikov, E. Exploiting Spatial Context in Nonlinear Mapping of Hyperspectral Image Data / E. Myasnikov // Lecture Notes in Computer Science. — 2017. — Vol. 10485. — P. 180-190.
17. Myasnikov, E. Nonlinear mapping based on spectral angle preserving principle for hyperspectral image analysis / E. Myasnikov // Lecture Notes in Computer Science. — 2017. — Vol. 10425. — P. 416-427.
18. Myasnikov, E.V. Analysis of Approaches to Feature Space Partitioning for Nonlinear Dimensionality Reduction / E.V. Myasnikov // Pattern Recognition and Image Analysis. — 2016. — Vol. 26(3). — P. 474-482.
19. Myasnikov, E.V. Evaluation of stochastic gradient descent methods for nonlinear mapping of hyperspectral data / E. Myasnikov // Lecture Notes in Computer Science. — 2016. — Vol. 9730. — P. 276-283.
20. Myasnikov, E.V. Hyperspectral image segmentation using dimensionality reduction and classical segmentation approaches / E.V. Myasnikov // Computer Optics. — 2017. — V. 41(4). — P. 564-572.
21. Myasnikov, E.V. The use of Interpolation Methods for Nonlinear Mapping / E. Myasnikov // Lecture Notes in Computer Science. — 2016. — Vol. 9972. — P. 649-655.
22. Myasnikov, E.V. The Choice of a Method for Feature Space Decomposition for Non-Linear Dimensionality Reduction / E.V. Myasnikov // Computer Optics. — 2014. — Vol. 38(4). — P. 790-797.
23. Myasnikov, E.V. A Nonlinear Method for Dimensionality Reduction of Data Using Reference Nodes / E.V. Myasnikov // Pattern Recognition and Image Analysis. — 2012. — Vol. 22(2). — P. 337-345.
24. Myasnikov, E.V. Nonlinear dimensionality reduction method with the use of reference nodes for analysis of digital image collections / E.V. Myasnikov // Pattern Recognition and Image Analysis. — 2011. — Vol. 21(2). — P. 312-315.
25. Мясников, Е.В. Определение параметров геометрических трансформаций для совмещения портретных изображений / Е.В. Мясников // Компьютерная оптика. — 2007. — Т. 31(3). — С. 77-82.
26. Глузов, Н.И. Метод отбора информативных признаков на цифровых изображениях / Н.И. Глузов, Е.В. Мясников // Компьютерная оптика. — 2007. — Т. 31(3). — С. 73-76.
- Материалы конференций в изданиях, индексируемых базами данных WoS / Scopus:*
27. Myasnikov, E. Visualization of feature spaces based on spectral and texture characteristics / E. Myasnikov // IEEE Xplore Digital Library, 9th IEEE International Conference on Information Technology and Nanotechnology. — 2023. — P. 1-5.
28. Myasnikov, E. Segmentation of hyperspectral images based on dimensionality estimation in spatial regions / E. Myasnikov // IEEE Xplore Digital Library, 2021 International Conference on Information Technology and Nanotechnology (ITNT). — 2021. — P. 1-4.
29. Myasnikov, E. Nearest Neighbor Search in Hyperspectral Data Using Binary Space Partitioning Trees / E. Myasnikov // IEEE Xplore Digital Library. Workshop on Hyperspectral Image and Signal Processing, Evolution in Remote Sensing (WHISPERS). — 2021. — P. 9484041.

30. Myasnikov, E. Dimensionality Reduction of Hyperspectral Images Based on the Linear Mixture Model and Dimensionality Estimation / E. Myasnikov // Proceedings of SPIE, Twelfth International Conference on Machine Vision (ICMV 2019). — 2020. - Vol. 11433. — P. 114331L.
31. Borisov, A. Performance Evaluation of Gradient-based Dimensionality Reduction Methods on Different Devices / A. Borisov, E. Myasnikov // 2020 Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT 2020). IEEE Xplore Digital Library. — 2020. — P. 428-431.
32. Borisov, A., Dimensionality reduction using GPU-accelerated gradient descent / A. Borisov, E. Myasnikov // CEUR Workshop Proceedings. — 2020. - Vol. 2667. - P. 248-250.
33. Myasnikov, E. Hyperspectral data dimensionality reduction using nonlinear autoencoders / E. Myasnikov // CEUR Workshop Proceedings. — 2020 — Vol. 2665. — P. 33-36.
34. Myasnikov, E. Using UMAP for Dimensionality Reduction of Hyperspectral Data / E. Myasnikov // 2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon). IEEE Xplore Digital Library. — 2020. - P. 1-5.
35. Myasnikov, E. Dimensionality reduction of hyperspectral images using autoassociative neural networks / E. Myasnikov // SIBIRCON 2019 - International Multi-Conference on Engineering, Computer and Information Sciences. IEEE Xplore Digital Library. — 2019. — P. 591-595.
36. Myasnikov, E. Evaluation of nonlinear dimensionality reduction techniques for classification of hyperspectral images / E. Myasnikov // CEUR Workshop Proceedings. — 2018. — Vol. 2268. — P. 147-154.
37. Myasnikov, E.V. Fast Techniques for Nonlinear Mapping of Hyperspectral Data / E.V. Myasnikov // Proc. of SPIE, Ninth International Conference on Machine Vision (ICMV 2016). - Vol. 10341. — P. 103411D.
38. Myasnikov, E.V. A Nonlinear Dimensionality Reduction Using Combined Approach to Feature Space Decomposition / E.V. Myasnikov // CEUR Workshop Proceedings. — 2015. - Vol. 1452. - P. 85-95.
39. Myasnikov, E.V. Nonlinear mapping methods with adjustable computational complexity for hyperspectral image analysis / E.V. Myasnikov // Proceedings of SPIE - The International Society for Optical Engineering. Eighth International Conference on Machine Vision (ICMV 2015). - 2015. -Vol. 9875. — P. 987508.
40. Myasnikov, E.V. Evaluation of Space Partitioning Data Structures for Nonlinear Mapping / E.V. Myasnikov // 23rd International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision (WSCG 2015) - Full Papers Proceedings. - 2015. - P. 109-118.