

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ УЧРЕЖДЕНИЕ
НАУКИ ИНСТИТУТ ВЫЧИСЛИТЕЛЬНЫХ ТЕХНОЛОГИЙ
СИБИРСКОГО ОТДЕЛЕНИЯ РОССИЙСКОЙ АКАДЕМИИ НАУК

На правах рукописи

Рылов Сергей Александрович

**МЕТОДЫ И АЛГОРИТМЫ СЕГМЕНТАЦИИ
МУЛЬТИСПЕКТРАЛЬНЫХ СПУТНИКОВЫХ
ИЗОБРАЖЕНИЙ ВЫСОКОГО
ПРОСТРАНСТВЕННОГО РАЗРЕШЕНИЯ**

Специальность 05.13.18 –
«Математическое моделирование, численные методы
и комплексы программ»

ДИССЕРТАЦИЯ
на соискание ученой степени
кандидата технических наук

Научный руководитель:
канд. физ.-мат. наук, доцент
Пестунов Игорь Алексеевич

Новосибирск – 2016

СОДЕРЖАНИЕ

Введение.....	4
Глава 1. Современное состояние проблемы сегментации спутниковых изображений высокого пространственного разрешения	10
1.1. Содержательная постановка задачи сегментации изображений и особенности обработки мультиспектральных спутниковых данных.....	10
1.2. Задача кластеризации и известные методы ее решения.....	16
1.2.1. Методы разбиений.....	18
1.2.2. Иерархические алгоритмы кластеризации.....	20
1.2.3. Алгоритмы спектральной кластеризации	22
1.2.4. Нейронные сети	23
1.2.5. Плотностные алгоритмы кластеризации.....	24
1.2.6. Сеточные алгоритмы кластеризации.....	28
1.2.7. Ансамблевые алгоритмы кластеризации	31
1.3. Методы спектрально-текстурной сегментации изображений	33
1.4. Краткие выводы по главе	39
Глава 2. Алгоритмы кластеризации мультиспектральных изображений на основе сеточного и ансамблевого подходов	40
2.1. Формальная постановка задачи кластеризации в рамках сеточного подхода	40
2.2. Сеточный алгоритм кластеризации ССА.....	42
2.3. Экспериментальное исследование алгоритма ССА.....	47
2.4. Метод построения ансамбля	55
2.5. Ансамблевый сеточный алгоритм кластеризации ЕССА	56
2.6. Экспериментальное исследование алгоритма ЕССА	58
2.7. Краткие выводы по главе	65
Глава 3. Иерархические алгоритмы кластеризации мультиспектральных изображений на основе сеточного и ансамблевого походов	66
3.1. Ультраметрика для построения иерархии данных в рамках сеточной структуры	66
3.2. Вычисление ультраметрики с помощью метода ближайшего соседа	68
3.3. Иерархический сеточный алгоритм кластеризации НСА.....	69

3.4. Экспериментальное исследование алгоритма НСА	72
3.5. Построение ансамбля иерархических разбиений	76
3.6. Иерархический сеточный алгоритм кластеризации НЕСА на основе ансамблевого подхода.....	78
3.7. Экспериментальное исследование алгоритма НЕСА	81
3.8. Краткие выводы по главе	86
Глава 4. Комбинирование спектральных и текстурных признаков при сегментации изображений	87
4.1. Метод описания мультиспектральной текстуры.....	87
4.2. Алгоритм спектрально-текстурной сегментации ESEG	88
4.3. Экспериментальное исследование алгоритма ESEG	90
4.4. Сегментация спутниковых изображений с учетом тематических масок	96
4.5. Краткие выводы по главе	99
Глава 5. Программное обеспечение на основе разработанных алгоритмов и решение практических задач.....	100
5.1. Программный комплекс «ЕССА-Pack» для сегментации мультиспектральных изображений	100
5.2. Автоматическое выделение водных объектов на спутниковых изображениях высокого разрешения для оперативного мониторинга паводковой ситуации....	103
5.3. Крупномасштабное моделирование структуры степной растительности с использованием снимков высокого разрешения.....	106
5.4. Краткие выводы по главе	111
Заключение	112
Список литературы	114
Публикации автора по теме диссертационной работы	128
Приложение 1. Свидетельство о государственной регистрации программы «ЕССА».	131
Приложение 2. Свидетельство о государственной регистрации программы «ESEG» .	132
Приложение 3. Свидетельство о государственной регистрации программы «ShadowExtractor»	133
Приложение 4. Акт внедрения результатов в СЦ ФГБУ «НИЦ «Планета»	134
Приложение 5. Акт внедрения результатов в Центральном сибирском ботаническом саду СО РАН.....	135

Введение

В настоящее время активно развиваются средства и технологии дистанционного зондирования Земли (ДЗЗ) из космоса. С каждым годом растет число запускаемых спутников с мультиспектральными сенсорами высокого (5 м и лучше) пространственного разрешения [2, 3]: WorldView-2/3, GeoEye-1, Pleiades-1A/1B, DMC-3, Kompsat-3/3A, KazEOSat-1, Ресурс-П (1/2/3) и др. Спутниковые данные незаменимы при решении задач, связанных с оперативным мониторингом протяженных или труднодоступных территорий [1]. Увеличение объема и информативности получаемых данных ДЗЗ способствует расширению круга решаемых с их помощью практических задач (мониторинг состояния окружающей среды, инвентаризация сельскохозяйственных угодий, лесоустройство и лесопользование, территориальное планирование, мониторинг и прогнозирование последствий чрезвычайных ситуаций и др.). Однако существенным фактором, ограничивающим применение мультиспектральных спутниковых изображений высокого разрешения, является отсутствие приемлемого инструментария для их автоматизированного анализа.

Одним из основных этапов анализа спутниковых изображений является сегментация, которая заключается в разбиении изображения на непересекающиеся области на основе схожести их спектральных, текстурных или других характеристик [1, 4, 5]. Методы сегментации позволяют выделять на спутниковых изображениях классы, соответствующие различным типам природных и антропогенных объектов [6-8]. При этом какие-либо априорные сведения о количестве классов и их вероятностных характеристиках, а также классифицированные обучающие выборки, как правило, отсутствуют. Кроме того на изображениях высокого пространственного разрешения существенно возрастает внутриклассовая неоднородность спектральных характеристик объектов [9-11]. Используемые в настоящее время методы сегментации, включенные в состав популярных программных пакетов (ERDAS Imagine, ENVI, ArcGIS, SNAP и др.) не учитывают особенности спутниковых изображений высокого разрешения [1, 8-13].

Наиболее распространенный подход к сегментации мультиспектральных спутниковых изображений в отсутствие обучающей выборки основан на использовании алгоритмов кластеризации данных в пространстве спектральных признаков [9, 14]. Широко используемые алгоритмы кластеризации (К-средних, ISODATA) основаны на предпо-

ложении о нормальном виде плотности распределения искомых классов и зачастую не обеспечивают требуемой достоверности результатов при анализе спутниковых изображений [8, 12]. С другой стороны, более подходящие в данном случае непараметрические алгоритмы, способные выделять кластеры произвольной формы, а также алгоритмы, позволяющие получать иерархическое представление данных, не получили широкого распространения из-за неприемлемо высокой вычислительной трудоемкости.

Кроме того, при сегментации спутниковых изображений высокого пространственного разрешения существенно возрастает информативность текстурных признаков [3, 9]. При этом применение методов, учитывающих лишь спектральные характеристики, зачастую приводит к чрезмерной раздробленности искомых классов [10, 11, 15]. К настоящему времени разработано большое количество эффективных методов формирования текстурных признаков для полутоновых изображений, однако для мультиспектральных изображений проблема спектрально-текстурной сегментации остается открытой [9, 11].

Таким образом, актуальной является задача разработки вычислительно эффективных непараметрических алгоритмов кластеризации и новых методов спектрально-текстурной сегментации для обработки мультиспектральных спутниковых изображений высокого пространственного разрешения.

Целью диссертационной работы является разработка вычислительно эффективных методов и алгоритмов сегментации мультиспектральных спутниковых изображений высокого пространственного разрешения.

Для достижения поставленной цели требовалось решить следующие задачи.

- Исследовать возможность применения существующих алгоритмов кластеризации и методов спектрально-текстурной сегментации для обработки мультиспектральных спутниковых изображений высокого пространственного разрешения.
- Разработать, теоретически обосновать и программно реализовать вычислительно эффективные непараметрические алгоритмы кластеризации, позволяющие работать в условиях малой априорной информации о вероятностных характеристиках классов.

- Разработать и программно реализовать вычислительно эффективный метод спектрально-текстурной сегментации мультиспектральных спутниковых изображений высокого пространственного разрешения.
- Провести экспериментальное исследование разработанных методов и алгоритмов на модельных и реальных данных.

Область исследования. Работа соответствует пунктам 3 «Разработка, обоснование и тестирование эффективных вычислительных методов с применением современных компьютерных технологий», 4 «Реализация эффективных численных методов и алгоритмов в виде комплексов проблемно-ориентированных программ для проведения вычислительного эксперимента» и 5 «Комплексные исследования научных и технических проблем с применением современной технологии математического моделирования и вычислительного эксперимента» паспорта специальности ВАК 05.13.18 – «Математическое моделирование, численные методы и комплексы программ» (технические науки).

Методология исследования опирается на современные информационно-вычислительные технологии. При решении поставленных задач использовались методы математической статистики, кластерного анализа, распознавания образов, обработки цифровых изображений, компьютерное моделирование, а также современные ГИС-технологии.

Экспериментальные исследования проводились с использованием программного комплекса, разработанного автором.

Научная новизна диссертационной работы состоит в следующем.

1. Предложены новые вычислительно эффективные непараметрические алгоритмы кластеризации данных, разработанные в рамках сеточного и ансамблевого подходов и позволяющие выделять кластеры разной формы, размера и плотности. Ансамблевый подход впервые применен для повышения устойчивости и качества результатов сеточного алгоритма кластеризации.
2. Предложены новые вычислительно эффективные иерархические алгоритмы кластеризации данных на основе сеточного и ансамблевого подходов, обеспечивающие разделение пересекающихся кластеров. Впервые предложен вычислительно эффективный метод построения ансамбля иерархических разбиений в рамках сеточного подхода.

3. Предложен новый метод описания мультиспектральной текстуры, не требующий введения единой метрики в пространстве разнородных спектрально-текстурных признаков. На его основе разработан вычислительно эффективный алгоритм спектрально-текстурной сегментации для мультиспектральных изображений.
4. Предложен новый метод автоматического выделения водных объектов на мультиспектральных спутниковых изображениях высокого пространственного разрешения, разработанный на основе предложенных алгоритмов кластеризации.

Практическая значимость полученных результатов обусловлена следующим. Разработанные методы и алгоритмы сегментации мультиспектральных спутниковых изображений превосходят ранее известные по качеству и скорости работы, что позволяет повысить эффективность автоматизированной обработки спутниковых данных высокого пространственного разрешения при решении прикладных задач.

Основные результаты работы были использованы при выполнении проектов РФФИ (№№ 14-07-31320-мол_а, 11-07-12083-офи_м, 11-07-00202-а, 13-07-12202-офи_м, 13-04-90446-Укр_ф_а), партнерского интеграционного проекта СО РАН № 74 и проекта РНФ № 14-14-00453.

Результаты диссертационной работы используются в Сибирском центре ФГБУ «НИЦ «Планета» (для оперативного мониторинга паводковой ситуации), а также в Центральном сибирском ботаническом саду СО РАН (для картографирования типов растительности по данным спутниковой съемки), что подтверждено актами о внедрении.

Основные положения, выносимые на защиту.

1. Разработанный в рамках сеточного подхода алгоритм кластеризации ССА и основанный на нем ансамблевый алгоритм ЕССА для сегментации мультиспектральных изображений.
2. Иерархический сеточный алгоритм кластеризации НСА и основанный на нем ансамблевый алгоритм НЕСА для сегментации мультиспектральных изображений.
3. Метод спектрально-текстурной сегментации мультиспектральных спутниковых изображений высокого пространственного разрешения ESEG.
4. Комплекс программ «ЕССА-Pack» для обработки и анализа мультиспектральных спутниковых данных, в котором реализованы разработанные автором методы и алгоритмы сегментации изображений.

5. Решение задачи оперативного мониторинга паводковой ситуации и задачи картографирования типов растительности по данным спутниковой съемки высокого пространственного разрешения с помощью разработанных методов и алгоритмов сегментации изображений.

Представление работы. Результаты работы были представлены на следующих научных мероприятиях: Всероссийской конференции молодых ученых по математическому моделированию и информационным технологиям (Новосибирск, 2011; Новосибирск, 2012; Томск, 2013; Тюмень, 2014; Красноярск, 2015); Международном научном конгрессе «ГЕО-Сибирь» (Новосибирск, 2012, 2013, 2015); Всероссийской открытой конференции «Современные проблемы дистанционного зондирования Земли из космоса» (Москва, 2013-2015); Всероссийской конференции «Обработка пространственных данных и дистанционный мониторинг природной среды и масштабных антропогенных процессов» (Барнаул, 2013); Международной научной конференции «Региональные проблемы дистанционного зондирования Земли» (Красноярск, 2014-2015); Российской конференции с международным участием «Распределенные информационно-вычислительные ресурсы» (Новосибирск, 2014); Open German-Russian Workshop on Pattern Recognition and Image Understanding (Germany, Koblenz, 2014); Всероссийской конференции «Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов» (с. Усть-Сема, Республика Алтай, 2015); Международной научно-практической конференции «Информационные технологии, системы и приборы в АПК – АГРОИНФО-2015» (НСО, п. Краснообск, 2015); научно-методическом семинаре «Информационно-вычислительные технологии в задачах поддержки принятия решений» в ИВТ СО РАН (Новосибирск, 2012-2016); объединенном семинаре (СЦ ФГБУ «НИЦ «Планета», ИВМиМГ СО РАН) «Дистанционное зондирование и цифровая обработка изображений» (Новосибирск, 2015); объединенном семинаре «Информационно-вычислительные технологии» в ИВТ СО РАН (Новосибирск, 2016).

Публикации. По теме диссертации опубликовано 18 печатных работ, в том числе 4 статьи в изданиях, рекомендованных ВАК, 6 – в других рецензируемых изданиях, 8 – в трудах международных и всероссийских конференций. Зарегистрировано 3 программы для ЭВМ.

Личный вклад автора. Автор принимал активное участие в постановке задач и интерпретации результатов. Сеточные алгоритмы кластеризации ССА и ЕССА разработаны автором совместно с Куликовой Е.А. и Бериковым В.Б. Все остальные представленные в диссертации методы и алгоритмы разработаны автором лично. Программная реализация, выбор алгоритмических решений, проведение численных экспериментов, работы по апробации и тестированию разработанных алгоритмов выполнены автором лично.

Структура и объем работы. Диссертация состоит из введения, пяти глав, заключения, списка литературы из 151 наименования и пяти приложений. Полный объем работы составляет 135 страниц, включая 40 рисунков и 4 таблицы.

Глава 1. Современное состояние проблемы сегментации спутниковых изображений высокого пространственного разрешения

1.1. Содержательная постановка задачи сегментации изображений и особенности обработки мультиспектральных спутниковых данных

Сегментация является одним из важнейших этапов в задачах автоматической обработки изображений [1, 4, 5]. В медицине она является инструментом выделения анатомических структур и других зон интересов, для которых обычно имеются априорные знания [1]. В машинном (компьютерном) зрении сегментация используется для выделения областей изображения, являющихся важными для дальнейшей высокоуровневой обработки. В дистанционном зондировании Земли методы сегментации используются для тематической обработки спутниковых снимков – выделения и анализа определенных объектов на изображении, таких как: здания, сооружения, дороги, водные объекты, различные типы растительности и т.п. [6, 7].

Сегментация изображений, в общем, определяется как процесс разделения изображения на однородные области так, чтобы каждая область была однородной, но никакое объединение двух смежных областей не было бы однородным. Такие области принято называть сегментами [1].

Важную роль в процессе сегментации играет выбор подходящей меры однородности, которая позволяет различать анализируемые объекты друг от друга. В основном используются спектральные и текстурные характеристики. При сегментации могут использоваться также другие признаки (форма, размер, контекст и т.п.) [1, 9].

В настоящее время основным типом данных, получаемых с помощью спутниковой съемки, являются мультиспектральные изображения [9]. При мультиспектральной съемке одновременно формируются несколько изображений одной и той же территории в различных зонах спектра электромагнитного излучения (спектральных каналах). Цветная фотография, в свою очередь, является частным случаем мультиспектральной съемки при выбранных трех спектральных зонах видимого света, соответствующих человеческому восприятию.

При сегментации мультиспектральных изображений первичными являются спектральные характеристики, при этом однородность сегментов определяется близостью их пикселей в спектральном (цветовом) пространстве признаков [9].

Другая часто применяемая мера однородности определяется близостью текстурных характеристик. Текстура определяется как повторяющаяся пространственная организация базовых примитивов, имеющих случайный характер, в локальной области изображения [16]. В цифровой обработке изображений для количественного описания текстуры применяются три основных подхода: статистический, структурный и спектральный [4]. Статистические методы оценивают статистические характеристики, определяемые на основе гистограммы локальной области или с помощью текстурной матрицы (матрица совместной встречаемости пар уровней тона соседних пикселей) [17]. Эти признаки позволяют охарактеризовать текстуру как гладкую, грубую, зернистую и т.п. Структурные методы анализируют взаимное положение простейших составляющих изображения. Спектральные методы основаны на свойствах Фурье-спектра и используются, прежде всего, для обнаружения глобальной периодичности в изображении по имеющим большую энергию узким выбросам на спектре [4].

Существуют также высокоуровневые подходы, учитывающие контекстную информацию и априорные знания для более качественной сегментации определенных заранее объектов. Эти подходы основаны на модели марковских случайных полей, мультимасштабной и объектно-ориентированной моделях и позволяют учитывать различные меры однородности [1].

Модель марковских случайных полей (Markov random field) является мощным инструментом для моделирования совместного распределения вероятностей пикселей изображения в рамках локальных пространственных взаимодействий [18]. Она позволяет учитывать пространственные связи и способна интегрировать различные виды признаков (помимо формы и размера) [1]. Однако данный метод является вычислительно трудоемким [1], а результаты значительно зависят от выбранных параметров модели [18].

Мультимасштабная модель (multi-resolution / multi-scale) предполагает определение объекта и его характеристик на соответствующем для него масштабе [19]. Реализация такого подхода возможна как «сверху-вниз», так и «снизу-вверх». В первом случае процесс начинается с «грубой» сегментации, и каждый сегмент может быть сегментирован на следующем шаге. Во втором случае начальными элементами выступают все

пиксели изображения, которые затем последовательно объединяются в соответствии с заданным критерием однородности. Процесс останавливается при достижении определенного размера сегментов [1]. Мультимасштабная модель была включена в коммерческое программное обеспечение (ПО) eCognition/Definiens Developer для сегментации данных дистанционного зондирования Земли.

В рамках объектно-ориентированной модели сегментации изображений (object-based image analysis, OBIA) происходит анализ и классификация на уровне объектов, т.е. групп пикселей, объединенных на основе определенной совокупности критериев [14]. При этом подходе в качестве признаков для классификации могут использоваться различные характеристики, такие как спектральные яркости объектов, их площадь, периметр, вытянутость, прямоугольность и др. [20]. Метод сегментации спутниковых изображений на основе объектно-ориентированного подхода включен в модуль Feature Extraction коммерческого ПО ENVI.

Описанные высокоуровневые подходы к сегментации позволяют выделять заранее определенные объекты на изображении, учитывая различные характерные признаки, в том числе контекст и априорные знания. Однако они требуют задания соответствующих параметров, для выбора которых требуются экспертные знания, что не позволяет считать данные методы автоматическими. Кроме того, в основе высокоуровневых подходов лежат базовые методы сегментации.

Распространенные методы сегментации изображений можно разделить на группы на основе операций, применяемых к изображению для формирования сегментов: попиксельные, граничные, на основе выделения однородных областей и гибридные (использующие сразу несколько стратегий) [1, 10, 14].

Методы попиксельной сегментации не учитывают отношения соседства пикселей или их положение на изображении, а относят их к кластерам на основе их близости в пространстве признаков (как правило, по спектральным характеристикам). Данная группа методов нашла широкое применение в дистанционном зондировании [9, 14]. Разделение данных на кластеры в пространстве признаков может осуществляться с помощью фиксированных порогов (пороговая гистограмма, дерево решений), однако это возможно только в отдельных случаях при наличии априорных знаний. На значения яркостей изображения, полученного со спутника, оказывает влияние множество случайных факторов, таких как состояние атмосферы и положение объекта относительно

съемочной системы (например, ориентация листьев) [21]. По своей природе значения спектральной яркости пикселей носят случайный характер, поэтому задачу разделения классов в пространстве спектральных признаков целесообразно решать в рамках вероятностно-статистического подхода [22].

В рамках этого подхода, в зависимости от наличия априорной информации, данная задача может рассматриваться как задача классификации с обучением (*классификация*) или задача классификации без обучения (*кластеризация*).

Пусть каждому пикселю d -спектрального изображения соответствует вектор, компонентами которого являются значения яркостей в d спектральных каналах. Таким образом, множество классифицируемых объектов X состоит из векторов, лежащих в d -мерном пространстве признаков $\mathbb{R}^d$: $X = \{x_i = (x_i^{(1)}, \dots, x_i^{(d)}) \in \mathbb{R}^d, i = \overline{1, N}\}$. В задаче классификации с обучением предполагается, что дополнительно имеется обучающая выборка $V = \{(x_i, y_i), i = \overline{1, N_V}\}$, где y_i – метка принадлежности вектора x_i к одному из информационных классов (классов интереса) $y_i \in Y = \{1, \dots, K\}$. Тогда задача классификации заключается в том, чтобы на основе анализа обучающей выборки V построить отображение (решающее правило) $f_V: X \rightarrow Y$, оптимизируя некоторый критерий качества. Таким образом, качество решающего правила в значительной мере зависит от имеющейся обучающей выборки. Для обучаемой классификации спутниковых снимков наиболее широко используется метод максимального правдоподобия, также широко используются метод опорных векторов и нейронные сети [8].

Одной из характерных особенностей задачи сегментации спутниковых изображений является отсутствие классифицированной обучающей выборки. В таком случае разделение классов природных объектов возможно лишь с использованием методов кластеризации. Предполагается, что имеется множество неклассифицированных объектов $X = \{x_i\}_{i=1}^N, x_i \in \mathbb{R}^d$. Задача кластеризации заключается в том, чтобы выделить в нем «закономерности» (группы схожести, кластеры) таким образом, чтобы объекты, принадлежащие одному кластеру, обладали схожими в некотором смысле характеристиками, а объекты из разных кластеров были несхожи. Подробнее алгоритмы кластеризации будут рассмотрены в разделе 1.2.

Вторая группа методов сегментации – граничные методы, которые основаны на выделении контуров объектов. Работа граничных методов разбивается на два этапа: поиск граничных пикселей с помощью градиентных фильтров (Робертса, Собела,

Лапласа, Кэнни и др.) и заполнение/замыкание границ [1, 5, 10, 14, 17]. В качестве метода заполнения контуров чаще всего используется алгоритм водораздела [1]. В этом случае градиент исходного изображения рассматривается в виде некоторого ландшафта, где значения градиента соответствуют значениям относительных высот. При заполнении данного ландшафта водой на участках с малыми значениями градиента образуются бассейны, а в точках с высокими его значениями пройдут линии водораздела, соответствующие границам однородных областей изображения [14]. Основным недостатком граничных методов является сильная зависимость от «шума», что зачастую ведет к пересегментации (особенно при наличии текстуры) [10, 15].

Третья группа включает методы на основе анализа областей (region based). Эти методы разделяют изображение на однородные области с помощью анализа пространственно близких пикселей и позволяют учитывать как спектральные, так и текстурные признаки. Это направление включает в себя методы наращивания областей, а также методы разделения и слияния областей [5], которые будут рассмотрены в разделе 1.3.

Несмотря на то, что разработано большое количество различных алгоритмов сегментации, не существует универсального метода, который бы хорошо работал для всех типов изображений [5, 14].

В задачах классификации спутниковых снимков традиционно используются классические алгоритмы классификации изображений: метод максимального правдоподобия для обучаемой классификации и алгоритмы К-средних и ISODATA для кластеризации [8]. Данные методы широко используются и включены в популярные программные пакеты для обработки спутниковых изображений: ENVI, ERDAS IMAGINE, ArcGIS, IDRISI, PCI Geomatica и др. Необходимо отметить, что традиционные методы попиксельной классификации исходят из предположения, что классы характеризуются многомерным нормальным распределением. Однако данное предположение не всегда верно для сложных реальных сцен, что может приводить к существенному снижению качества классификации [8, 9, 12].

С каждым годом растет число запускаемых спутников, обеспечивающих поставку мультиспектральных изображений высокого пространственного разрешения (5 м и лучше) [2, 3]. С увеличением пространственного разрешения размер пикселя оказывается меньше размера исследуемых объектов [1]. Это приводит к увеличению внутриклассовой спектральной неоднородности [10, 11]. Например, освещенные и теневые стороны

деревя имеют заметно различные спектральные отклики, хотя они и принадлежат к одному информационному классу. Увеличение неоднородности уменьшает статистическую разделимость классов в спектральном пространстве признаков. Данная проблема затрудняет работу традиционных методов классификации, которые неспособны выделять многомодовые классы сложной формы, и в таких случаях часто приводят к раздробленности классов на множество мелких спектральных подклассов, проявляя так называемый «эффект соли и перца» (salt and pepper effect) [1, 10, 11, 15].

Кроме того, на спутниковых изображениях высокого разрешения значительная часть информации о представленных на них объектах заключена в текстурных характеристиках, поэтому при сегментации важно учитывать не только спектральные, но и текстурные признаки [9, 3]. К настоящему времени известен ряд эффективных методов формирования текстурных признаков для полутонных изображений, однако проблема спектрально-текстурной сегментации мультиспектральных изображений остается открытой [9, 11].

Таким образом, можно выделить четыре характерные особенности задачи сегментации мультиспектральных спутниковых изображений высокого пространственного разрешения. Первая особенность заключается в большом объеме обрабатываемых данных [9]. Современные спутниковые изображения содержат порядка $10^6 - 10^8$ элементов разрешения (пикселей). При исследовании природных объектов получение информации об исследуемых объектах зачастую связано со значительными материальными и временными затратами [13, 23]. Поэтому на практике обучающая выборка может отсутствовать или быть не представительной. Особенно остро эта проблема ощущается при исследовании обширных и труднодоступных территорий, где спутниковые изображения являются единственным источником актуальной и объективной информации. Недостаток (или отсутствие) априорной информации о количестве и вероятностных характеристиках классов, присутствующих на изображении, является второй особенностью рассматриваемой задачи. Третья особенность состоит в присутствии на изображениях «шума» и выбросов, обусловленных особенностями функционирования съемочной аппаратуры, условиями съемки и др. Четвертой особенностью при обработке спутниковых изображений высокого пространственного разрешения является наличие значительной неоднородности значений спектральных яркостей в рамках распознаваемых классов.

Указанные особенности мультиспектральных спутниковых изображений высокого пространственного разрешения порождают следующие требования к используемым алгоритмам сегментации [9]:

- высокое быстродействие при обработке больших массивов данных;
- возможность совместного использования спектральных и текстурных признаков;
- способность выделения кластеров различного размера, формы и плотности в условиях минимальной априорной информации;
- возможность выделения заранее неизвестного числа кластеров;
- устойчивость к наличию «шума» в данных;
- простота настройки параметров.

1.2. Задача кластеризации и известные методы ее решения

Один из наиболее распространенных подходов к сегментации спутниковых изображений при отсутствии обучающей выборки основан на использовании алгоритмов кластеризации данных. Кластеризация является фундаментальным инструментом в задачах распознавания и обучения и имеет длинную и богатую историю развития в различных научных сферах. В общей (содержательной) постановке *задача кластеризации* состоит в том, чтобы разбить множество классифицируемых объектов на сравнительно небольшое число (заранее известное или нет) непересекающихся подмножеств, называемых *кластерами*, так, чтобы каждый кластер состоял из схожих объектов, а объекты разных кластеров существенно отличались [24]. При этом вопрос определения количества кластеров в данных и выбора меры схожести не имеет однозначного ответа и, как правило, они выбираются исходя из особенностей решаемой задачи [25].

Общую формальную постановку к задаче кластеризации можно записать следующим образом. Пусть множество классифицируемых объектов X состоит из векторов, принадлежащих пространству признаков $\mathbb{R}^d$: $X = \{x_i = (x_i^{(1)}, \dots, x_i^{(d)}) \in \mathbb{R}^d, i = \overline{1, N}\}$. Иногда, в силу особенностей решаемой задачи, выборка X описывается матрицей коэффициентов попарного сходства/различия. Задача кластеризации заключается в разбиении множества X на непустые кластеры $C_i, i = 1, \dots, K$, такие, что $X = \bigcup_{i=1}^K C_i$ и $C_i \cap C_j = \emptyset$, при $i \neq j$, в соответствии с некоторым критерием ($R(X) \rightarrow \min$).

К настоящему времени известно несколько сотен различных алгоритмов кластеризации многомерных данных. Опубликовано множество обзорных статей и монографий, посвященных кластеризации (например, [24-31]). Большое количество публикаций свидетельствует о сложности проблемы и невозможности создания универсального алгоритма кластеризации [24, 32].

На рисунке 1.1 представлена модель двумерных данных, содержащих кластеры различной формы, размера и плотности, а также «шум». По утверждению Anil K. Jain [24], на момент публикации ни один из доступных алгоритмов кластеризации не был способен правильно обнаружить и выделить все 7 кластеров.




Рисунок 1.1 – Модель данных, содержащих кластеры, различной формы, размера и плотности (а); желаемый результат кластеризации (б)

Среди алгоритмов кластеризации можно выделить следующие основные группы: методы разбиений, иерархические, плотностные, сеточные алгоритмы, а также алгоритмы спектральной кластеризации и нейронные сети [9, 27, 28, 30]. Нередко алгоритмы одновременно принадлежат нескольким указанным группам, поэтому приведенная систематизация не является строгой.

При выборе подходящего алгоритма кластеризации необходимо учитывать следующие ключевые характеристики [28, 33]: способность обрабатывать большие массивы данных; устойчивость к наличию «шума» и выбросов в данных; быстродействие (вычислительная сложность); возможность выделять кластеры произвольной структуры (формы, размера и плотности); простота настройки параметров; стабильность (независимость результата от порядка ввода данных или запуска); способность обрабатывать данные большой размерности; возможность работать с нечисловыми типами

данных. Для кластеризации мультиспектральных спутниковых изображений важны все перечисленные свойства за исключением последних двух [9]. Далее рассматриваются основные группы алгоритмов кластеризации и их характерные свойства.

1.2.1. Методы разбиений

Наиболее распространенными являются методы разбиений (partitioning methods). Они основаны на итеративном изменении некоторого начального разбиения исходного множества до получения минимального значения целевой функции. В качестве целевой функции обычно выступает сумма квадратов расстояний от объектов до центров кластеров, к которым они отнесены.

Для кластеризации множества объектов $X = \{x_i = (x_i^{(1)}, \dots, x_i^{(d)}) \in \mathbb{R}^d, i = \overline{1, N}\}$ на K кластеров $\{C_1, \dots, C_K\}$ оптимизационный критерий выглядит следующим образом:

$$\sum_{j=1}^K \sum_{x_i \in C_j} \|x_i - c_j\|^2 \rightarrow \min_{c_1, \dots, c_K},$$

где c_j – центр кластера C_j .

Глобальная оптимизация данного критерия является NP-трудной комбинаторной оптимизационной задачей. Количество возможных разбиений огромно даже при малых значениях N и K , поэтому на практике используются эвристические схемы, сходящиеся к локальному оптимуму [25].

Самым известным представителем данной группы является алгоритм кластеризации К-средних (K-means) [34]. Несмотря на то, что алгоритм был предложен более 50 лет назад, он остается одним из самых широко используемых алгоритмов кластеризации в различных задачах [30]. Этот успех связан с его простотой и одновременно высокой эффективностью. К-средних является реализацией жадного алгоритма для представленного оптимизационного критерия. Сначала случайным образом выбираются начальные положения K центров кластеров. Итерация алгоритма состоит в разделении данных на кластеры, где каждый элемент относится к ближайшему центру. После чего вычисляются новые центры кластеров (как центры масс). Процедура повторяется до тех пор, пока не стабилизируется состав кластеров.

Вычислительная сложность алгоритма практически линейно зависит от числа элементов данных и составляет $\mathcal{O}(NdK)$ при ограниченном числе итераций. Это позволяет алгоритму обрабатывать большие объемы данных с высокой скоростью. Алгоритм К-средних требует задания трех входных параметров: число кластеров K , положение

начальных центров и функцию расстояния. Выбор K сильно влияет на результат кластеризации, поэтому необходимость его задания считается значительным недостатком [24]. Другой проблемой является сходимость к локальному решению. Различные инициализации центров могут приводить к разным результатам. Частично это преодолевается множественным запуском алгоритма при различных инициализациях центров с итоговым выбором разбиения с наименьшей квадратичной ошибкой [24]. От выбора используемой функции расстояния зависит форма получаемых кластеров. Обычно используется евклидово расстояние, в результате алгоритм K -средних находит кластеры сферической формы. Расстояние Махаланобиса применяется для выделения гиперэллиптических кластеров, но это приводит к более высоким вычислительным затратам. Кроме того, алгоритм K -средних чувствителен к «шуму» и выбросам, т.к. при вычислении центров используются все элементы кластера.

Существует множество модификаций алгоритма K -средних. К ним относятся ISODATA, FORGY, K -medoids, CLUSTER и WISH [30]. Для некоторых из них необходимо задание минимального размера кластеров, также возможны дополнительные слияния и разделения кластеров. Алгоритм кластеризации Fuzzy C-means (FCM), является расширением K -средних на основе нечеткой логики, где каждый элемент данных характеризуется коэффициентами принадлежности к каждому из кластеров [35]. Самая распространенная модификация алгоритма K -средних – ISODATA [36] – позволяет динамически корректировать число кластеров, разделяя или объединяя их на основе настраиваемых параметров. Достаточно близкие кластеры могут объединяться, а слишком большие – разбиваться, что позволяет справляться с выбросами в данных. Алгоритм кластеризации ISODATA реализован во многих программных пакетах для обработки спутниковых изображений и поэтому активно используется на практике [8].

Методы разбиений включают в себя также алгоритмы: K -modes, PAM, CLARA, CLARANS, FOREL, SKAT, KOLAPS, FINDIT и др. [28, 30, 37, 38].

Общим недостатком алгоритмов данного типа является неспособность выделять кластеры произвольной формы. Эти алгоритмы базируются на предположении о сферической форме кластеров, что зачастую приводит к ошибкам кластеризации или излишней раздробленности информационных классов. Также существенным недостатком многих представителей данной группы является сильная зависимость результата от настраиваемых параметров и необходимость жесткого задания числа кластеров.

1.2.2. Иерархические алгоритмы кластеризации

Иерархические алгоритмы кластеризации позволяют получать систему вложенных разбиений, соответствующих различным уровням иерархии, которая представляется в виде дерева, называемого *дендрограммой*. При этом степень подробности разбиения данных можно варьировать с помощью среза дендрограммы на разных уровнях [25]. Иерархическое представление удобно при интерпретации результатов, когда требуется информация о различных уровнях кластерной структуры, а также в ситуациях, когда точное число искоемых кластеров неизвестно [39].

Иерархические алгоритмы разделяются на агломеративные или разделительные [24]. Агломеративные алгоритмы начинают работу с каждой точки данных как одноэлементного кластера, последовательно объединяя наиболее близкие пары кластеров для формирования иерархии. Объединение классов заканчивается, когда выполняется остановочный критерий, либо когда все элементы объединяются в единый класс. Разделительный способ (*divisive*) рассматривает всю выборку как один начальный кластер и затем рекурсивно разделяет каждый кластер на меньшие кластеры. Для данных из N элементов сложность поиска разделения составляет $O(2^{N-1})$, поэтому разделительные методы на практике не используются [25].

Общая схема агломеративного алгоритма кластеризации для N объектов состоит из следующих шагов.

1. Вычислить матрицу расстояний (МР) между классифицируемыми объектами.
Повторить $(N - 1)$ раз пункты 2 и 3.
2. Найти минимальный элемент в МР и объединить соответствующие кластеры.
3. Обновить МР, вычислить расстояния от нового кластера до всех остальных.

Таким образом, агломеративные иерархические алгоритмы кластеризации различаются в выборе функции расстояния между базовыми элементами и способе определения расстояния до групп элементов [30]. В качестве функции расстояния может выступать какая-либо метрика, например, евклидово или манхэттенское расстояние. Самые известные способы вычисления расстояний между двумя множествами A и B (*linkage criteria*) приведены в таблице 1.1.

Выбор способа пересчета расстояний сильно влияет на результаты кластеризации. Например, методы дальнего соседа и средней связи хорошо работают с кластерами сферической формы. Метод ближайшего соседа способен выделять кластеры сложной

формы, но при этом сильно подвержен влиянию «шума», так называемому «цепочному эффекту» [40]. Кроме того, у методов иерархической кластеризации возникают трудности с разделением пересекающихся кластеров [41].

Таблица 1.1 – Способы вычисления расстояний между двумя множествами (A и B)

Метод ближайшего соседа (single linkage)	$\min \{d(a, b): a \in A, b \in B\}$
Метод дальнего соседа (complete linkage)	$\max \{d(a, b): a \in A, b \in B\}$
Метод невзвешенной средней связи (UPGMA)	$\frac{1}{ A B } \sum_{a \in A} \sum_{b \in B} d(a, b)$

В общем случае, вычислительная сложность представленного иерархического алгоритма составляет $\mathcal{O}(N^3)$. Для методов ближайшего соседа и дальнего соседа существуют алгоритмы с оптимальной сложностью $\mathcal{O}(N^2)$ [42, 43]. Тем не менее, высокая трудоемкость базовых иерархических алгоритмов кластеризации не позволяет применять их для обработки больших массивов данных [44].

Существует ряд других алгоритмов кластеризации, позволяющих получить иерархическую структуру данных: BIRCH, CURE, ROCK, OPTICS, CHAMELEON [45].

Алгоритм BIRCH [46] базируется на идее, что элементы данных можно рассматривать группами. На первом этапе алгоритм группирует данные в сбалансированное по высоте дерево, называемое CF-деревом [30]. Затем дополнительно анализируются листья полученного дерева: близкие листья могут быть объединены, а другие могут быть определены как «выбросы/шум». После этого к полученным листьям дерева (под-кластерам) применяется агломеративная иерархическая кластеризация. На заключительном этапе центры полученных кластеров могут быть использованы для перераспределения данных, при этом слишком отдаленные от центров элементы относятся к «шуму».

Алгоритм BIRCH достигает линейной вычислительной сложности $\mathcal{O}(N)$ и позволяет обрабатывать большие массивы данных, а также справляться с «шумом» [25]. Однако алгоритм не позволяет выделять кластеры произвольной формы, так как использует концепции радиуса для определения границ кластеров [28]. Кроме того, результат работы алгоритма зависит от порядка ввода данных.

В отличие от BIRCH, алгоритм CURE [47] позволяет выделять кластеры различной формы и размера. Алгоритм использует агломеративный подход, на каждой

итерации объединяя кластеры с наиболее близкими представителями. В качестве представителей выступают случайно выбранные элементы, сдвинутые в направлении центра кластера на некоторую относительную величину. Такой подход позволяет повысить устойчивость к «шуму» и выделять кластеры сложной формы, при этом существенно увеличивает вычислительную сложность, которая составляет $\mathcal{O}(N^2 \cdot \log N)$ [30].

Алгоритм ROCK [48] был разработан для работы с нечисловыми данными. Он основан на применении алгомеративной кластеризации. Основная идея состоит в том, что между каждой парой объектов рассчитывается количество общих связей.

Плотностной алгоритм OPTICS [49] также позволяет выделить иерархическую структуру и кластеры сложной формы. Данные упорядочиваются в остовное дерево таким образом, чтобы пространственно близкие элементы располагались рядом. При этом иерархия представляется в виде диаграммы достижимости, на которой отмечаются расстояния достижимости для построенной последовательности элементов. Пики на диаграмме соответствуют разделениям между кластерами, а их высота – расстоянию. При необходимости по диаграмме достижимости можно легко построить дендрограмму. Так как для каждого элемента рассматриваются только соседние элементы в ограниченном радиусе ε , алгоритм OPTICS можно реализовать с вычислительной сложностью $\mathcal{O}(N \cdot \log N)$, что не является достаточным для обработки больших массивов данных. Другие существующие иерархические алгоритмы, использующие плотностной подход, также имеют вычислительную сложность $\mathcal{O}(N \cdot \log N)$ или хуже: DeLiClu [50], PHA [41], k-NN ITC [51].

Информация об иерархической структуре кластеров может быть полезной для интерпретации результатов кластеризации изображений, однако из-за высокой трудоемкости существующие иерархические алгоритмы кластеризации не применимы для обработки спутниковых изображений [52].

1.2.3. Алгоритмы спектральной кластеризации

Спектральная кластеризация, известная также как теоретико-графовый подход, возникла в рамках решения проблемы разбиения взвешенного неориентированного графа [24]. Элементы данных представляются в виде вершин графа, а вес соединяющих их ребер соответствует схожести (близости) этих элементов. Основная идея кластериза-

ции заключается в разделении вершин графа на подмножества так, чтобы минимизировать сумму весов ребер, соединяющих эти подмножества [53].

В качестве меры схожести чаще всего используется гауссово ядро (Gaussian kernel function) $s(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / (2\sigma^2))$, где σ – параметр сглаживания [54]. Существует несколько способов построения графа: полный граф, в котором для каждой пары элементов существует ребро; ε -граф, где вершины соединяются только, если расстояние между ними не превышает некоторого заданного ε ; k -ближайших соседа (k -NN), где каждая вершина соединяется ребром с k ближайшими вершинами [55].

Задача кластеризации состоит в разрезе графа на два или несколько подграфов, минимизируя определенный критерий. Как правило, используется критерий «Normalized cuts» [55]. Поиск такого разреза является NP-трудной дискретной оптимизационной задачей [54]. Поэтому ищется приближенное решение с помощью спектральной теории графов. При этом задача сводится к поиску собственных векторов нормализованной матрицы Кирхгофа, получаемой из матрицы смежности построенного графа [53].

Спектральная кластеризация позволяет получать качественные результаты и выделять сложно разделимые кластеры, но при большом объеме данных вычислительная сложность достигает $O(N^3)$ [53]. Для ускорения вычислений используются различные приемы: методы уменьшения рабочей выборки [56], предварительная группировка и др. [13, 57]. Несмотря на эти модификации, разработанные алгоритмы спектральной кластеризации характеризуются квадратичной вычислительной сложностью, и время обработки даже небольших изображений на современном ПК занимает несколько часов [53, 56]. Существует несколько методов, применяющих спектральную кластеризацию к спутниковым изображениям. Однако в них обрабатываются не сами элементы данных, а их представители, такие как: гистограммы сегментов изображения размера 100×100 пикселей [58] или «прототипы», полученные нейросетевым алгоритмом Neural Gas [13], что в итоге затрудняет выделение сложно разделимых кластеров.

1.2.4. Нейронные сети

Искусственные нейронные сети представляют собой систему соединенных между собой слоев искусственных нейронов. Искусственный нейрон имеет некоторое количество входов, каждому из которых соответствует определенный вес. Нейрон рассчитывает выходной сигнал как линейную комбинацию всех входных сигналов. Нейронные сети

используют в задачах распознавания образов, прогнозирования и классификации, предварительно обучая сеть. Для кластеризации используются самообучающиеся сети.

Самым распространенным методом кластеризации является самоорганизующаяся карта Кохонена (self-organising map, SOM) [59]. Количество нейронов равно количеству кластеров и задается как параметр. Каждый нейрон описывается весовым вектором, имеющий такую же размерность, что и входные данные. В процессе обучения для каждого элемента данных выбирается наиболее похожий по весовому вектору нейрон (победитель), и значение его вектора-веса приближается к текущему элементу. Также приближаются весовые векторы нескольких близлежащих узлов. Циклический процесс обучения, перебирающий входные данные, заканчивается по достижении картой допустимой погрешности, или при достижении заданного количества итераций.

Существует несколько других методов кластеризации на основе нейронных сетей: CDL, НЕС, SPLL, Neural Gas [25, 60], которые также основаны на использовании векторов-прототипов для представления кластера.

Нейросетевые алгоритмы кластеризации характеризуются устойчивостью к «шуму» и способностью обрабатывать многомерные данные. Главным недостатком этих методов считается необходимость жесткого задания числа кластеров [25]. Результат работы алгоритмов данного типа зависит от порядка ввода данных и инициализации начальных параметров. Кроме того, эти методы не позволяют выделять кластеры сложной формы без дополнительных модификаций [61]. Другой проблемой для их практического применения является высокая вычислительная сложность. В работе [23] было показано, что для сегментации спутниковых изображений Landsat-5 TM алгоритму SOM требуется более 20000 итераций.

1.2.5. Плотностные алгоритмы кластеризации

Плотностные методы (density-based methods) рассматривают задачу кластеризации в рамках вероятностно-статистического подхода. При этом классифицируемые элементы считаются реализацией некоторой многомерной случайной величины, плотность распределения которой неизвестна. Кластеры определяются как области в пространстве признаков с высокой плотностью распределения, разделенные областями с низкой плотностью [9, 24].

Плотностные методы кластеризации делятся на параметрические (model-based) и непараметрические. Параметрический подход подразумевает, что плотность распределения данных параметризована и характеризуется фиксированным набором параметров. Например, нормальное распределение описывается двумя параметрами: математическим ожиданием и среднеквадратичным отклонением. Непараметрический подход, в свою очередь, не требует жестких предположений о виде функции плотности распределения данных. Таким образом, сложность описания функции плотности зависит от самих рассматриваемых данных, а не от заданной заранее модели.

В параметрических методах предполагается, что данные моделируются смесью распределений (чаще всего, нормальных), где каждый кластер описывается одной из компонент смеси [24]. Задача кластеризации сводится к оценке неизвестных параметров функций распределений методом максимального правдоподобия. Для этого используются итеративные алгоритмы, самым известным из которых является ЕМ (Expectation maximization) [62]. Предполагается, что количество кластеров заранее известно (задано) и все классы имеют нормальное распределение с неизвестными параметрами. Сначала параметры инициализируются случайным образом, затем на каждой итерации они корректируются, увеличивая ожидаемое правдоподобие, вплоть до достижения локального оптимума. Другие алгоритмы и программы на основе моделей распределений включают в себя [25]: GMDD, AutoClass, MCLUST, Multimix, EMMIX, Snob.

Параметрические алгоритмы устойчивы к влиянию выбросов и «шума», а также позволяют получать качественные результаты при условии выбора модели, соответствующей действительности. Но при отсутствии априорных сведений о количестве классов и их параметрической структуре получение адекватных результатов кластеризации может оказаться невозможным. Кроме того, данный подход характеризуется высокой вычислительной сложностью [25].

Для качественной сегментации изображений алгоритм не должен делать предположений о форме распределения и числе искомых кластеров [33]. Непараметрические методы позволяют выделять кластеры сложной, заранее не определенной формы. Для непараметрической оценки плотности распределения данных наиболее распространенными являются гистограммная оценка, оценка плотности на основе ближайших соседей и оценка Розенблатта–Парзена.

Гистограммные методы оценивают плотность дискретно с помощью построения многомерной гистограммы в пространстве признаков. При выполнении определенных условий гистограммная оценка является состоятельной [63]. Кластеры в данном случае соответствуют «холмам» на гистограмме [33]. Ярким примером такого подхода является алгоритм [64]. Результаты кластеризации при этом подходе значительно зависят от параметра дискретизации пространства признаков. В работе [65] для преодоления этой проблемы был предложен алгоритм, адаптивно увеличивающий разрешение гистограммы в областях с большей плотностью.

Второй широко распространенный подход для непараметрической оценки плотности заключается в том, что плотность характеризуется числом близлежащих элементов [30]. Таким образом, близость пары элементов определяется числом общих соседних элементов. Самым ярким представителем данного подхода является алгоритм кластеризации DBSCAN [66]. Его идея состоит в том, что если у элемента в радиусе ϵ содержится не менее заданного числа (MinPts) соседних элементов, то все его «соседи» помещаются вместе с ним в один кластер. Элементы, не имеющие достаточного числа «соседей» и не попавшие в какой-либо кластер, относятся к «шуму». DBSCAN позволяет выделять кластеры сложной формы и справляться с выборами и «шумом» в данных. Недостатками алгоритма являются сложность настройки значений параметров (ϵ и MinPts) [9] и трудности при выделении кластеров с существенно различающейся плотностью. Для преодоления этих проблем были предложены алгоритмы OPTICS и DeLiClu.

Алгоритм OPTICS [49] является обобщением DBSCAN, где элементы упорядочиваются в остовное дерево таким образом, чтобы пространственно близкие элементы находились рядом. При этом отпадает необходимость тщательной настройки подходящего параметра ϵ , и в результате получается иерархический результат [30]. Однако параметр ϵ задается в алгоритме как максимальный рассматриваемый радиус. В идеале его можно задавать очень большим, но это приводит к непомерным вычислительным затратам. Полностью избавиться от параметра ϵ удалось алгоритму DeLiClu [50], сочетающему в себе идеи алгоритмов OPTICS и SLINK, при этом требуя задавать только один параметр: MinPts.

Другими представителями рассматриваемого подхода к оценке плотности являются алгоритмы: GDBSCAN [67], HiCO [68], Fast-VDP [69].

Общей проблемой алгоритмов данной группы является вычислительная сложность $\mathcal{O}(N \cdot \log N)$ (или хуже), что ограничивает их применение при обработке больших массивов данных [9].

Третий подход основан на непараметрической оценке плотности Розенблатта–Парзена. Плотность в точке пространства признаков оценивается как суммарное влияние элементов выборки. При этом вклад каждого элемента описывается невозрастающей функцией (ядром) $K(x)$, зависящей от расстояния до этого элемента. Формула для вычисления оценки плотности $f(x)$ с параметром сглаживания h в произвольной точке имеет вид [70]:

$$\hat{f}_h(x) = \frac{1}{Nh^d} \sum_{i=1}^N K\left(\frac{x - x_i}{h}\right).$$

В качестве $K(x)$ чаще используется ядро Гаусса или ядро Епанечникова [71]:

$$K_G\left(\frac{x - x_i}{h}\right) = \exp\left(-\frac{\|x - x_i\|^2}{2h^2}\right);$$

$$K_{Ep}\left(\frac{x - x_i}{h}\right) = \left(1 - \frac{\|x - x_i\|^2}{h^2}\right) \cdot I(\|x - x_i\| \leq h), \text{ где } I(x) - \text{индикаторная функция.}$$

При таком подходе кластеры соответствуют локальным максимумам функции оценки плотности (моды). Элементы данных относятся к кластерам с помощью процедуры восхождения на вершину (hill climbing), сходящейся к соответствующему локальному максимуму [33]. Для этого используется метод «среднего сдвига» (Mean shift) [72]. Итеративная процедура «среднего сдвига», начиная свою работу с точки x_0 , последовательно перемещается в точку сдвига $x_{k+1} = m(x_k)$ вплоть до сходимости, где:

$$m(x) = \sum_{i=1}^N \frac{x_i \cdot K(x - x_i)}{K(x - x_i)}.$$

Вектор $(m(x) - x)$ называется вектором «среднего сдвига» и его направление совпадает с направлением максимального роста плотности в точке x .

На основе этого подхода предложено множество алгоритмов кластеризации [3]: Mean shift, Medoid shift, Quick shift, Variable-bandwidth Mean shift и др. Некоторые алгоритмы используют сеточную структуру для оптимизации вычислений при ограниченном ядре: DENCLUE [73], FHS [33].

Недостатком использования оценки плотности Розенблатта–Парзена является сильная зависимость результатов от параметра сглаживания h . Кроме того, фиксиро-

ванное значение h затрудняет выделение кластеров различных размеров, поэтому предлагаются алгоритмы с адаптивным выбором параметра h [33]. Основной проблемой для использования данного подхода при обработке больших массивов данных является нелинейная вычислительная сложность [70]. В связи с этим, для ускорения процедуры среднего сдвига было предложено множество методик [74]: использование ограниченного ядра и сеточной структуры, уменьшение выборки (семплирование), распараллеливание. Это позволяет сократить время работы алгоритма на несколько порядков, тем не менее, вычислительная сложность алгоритмов составляет не менее $O(N \cdot \log N)$ [71].

Алгоритмы, основанные на непараметрической оценке плотности распределения, привлекательны тем, что позволяют выделять кластеры, имеющие сколь угодно сложную структуру, при наличии «шума» [9]. Однако их общим недостатком является высокая трудоемкость, что затрудняет их применение для обработки спутниковых изображений. Кроме того, плотностные методы напрямую неприменимы для обработки данных большой размерности из-за так называемого эффекта «проклятия размерности» [24].

1.2.6. Сеточные алгоритмы кластеризации

Сеточные алгоритмы кластеризации (grid-based) [75, 76] основаны на введении сеточной структуры в пространстве признаков. Предполагается, что элементы данных, попавшие в одну ячейку сетки, с высокой вероятностью принадлежат одному кластеру [9]. Таким образом, осуществляется переход от обработки данных к обработке элементов сеточной структуры (*клеток*), количество которых, как правило, сравнительно мало. Данный подход позволяет добиться высокой скорости работы (линейной вычислительной сложности) и обрабатывать большие массивы данных [28]. Кроме того, сеточные алгоритмы позволяют выделять кластеры сложной формы и не зависят от порядка ввода данных.

Наиболее распространенными являются алгоритмы, формирующие одну фиксированную сетку, в которой число разбиений по каждой размерности задается пользователем. Каждая клетка характеризуется объемом и количеством попавших в нее элементов данных. Клетки разделяются по порогу на плотные и неплотные («пустые»). Соседние плотные клетки связываются в кластеры, которые отделяются неплотными областями. На этом базовом подходе основаны многие сеточные алгоритмы: NRI [77], TSING [78], SLS [79] и др.

Широко известный алгоритм CLIQUE [80] реализует описанный подход для обработки данных высокой размерности. Количество клеток экспоненциально зависит от размерности пространства признаков, поэтому при высоких размерностях хранятся только непустые клетки. Сначала алгоритм CLIQUE выделяет плотные области (интервалы) во всех одномерных проекциях данных, которые затем используются при формировании кластеров в многомерном пространстве признаков. Однако использование проекций не обеспечивает выделения всех имеющихся кластеров, что может приводить к серьезным ошибкам кластеризации [9].

Сеточный алгоритм кластеризации WaveCluster [81] основан на ином подходе к выделению кластеров. Сеточная структура рассматривается как цифровой сигнал, значение которого в ячейке определяется количеством попавших в нее элементов данных. Для выделения плотных областей применяется вейвлет-преобразование, разделяющее сигнал по частотам. Внутренней области кластера соответствует низкочастотный сигнал с большой амплитудой, а границам кластеров – высокочастотный сигнал. Преимуществом алгоритма WaveCluster является получение результатов различной степени подробности (в зависимости от разрешения вейвлет-преобразования).

Базовый подход, различающий только плотные и неплотные ячейки сетки, испытывает проблемы с разделением пересекающихся кластеров, а также с выделением кластеров с сильно различающейся плотностью [82]. Преодолеть эту проблему позволяет комбинация плотностного и сеточного подходов, когда плотности в ячейках сравниваются не только с пороговым значением, но и между собой [83].

Алгоритмы CGDCP [84], ICECPG [85] и GRIDCLUS [86] для нахождения кластеров используют процедуру восхождения на вершину: клетки соединяются с соседними клетками, имеющими большую плотность. Это позволяет выделять одномодовые кластеры, разделенные перепадами плотности.

В алгоритме GDCLU [83] достаточно плотные клетки связываются в кластеры, если соседние клетки в кластере имеют близкие значения плотности. Если же плотность соседних клеток сильно различается, то они относятся к разным кластерам.

Алгоритмы, использующие одну фиксированную сетку, обладают высокой вычислительной эффективностью, однако их общим недостатком является сильная зависимость результатов кластеризации от выбранного размера ячеек [76]. При крупном масштабе сетки возможны проблемы с разделением близких кластеров, а также значи-

тельное огрубление границ кластеров. С другой стороны, при слишком мелком размере клеток происходит излишнее дробление кластеров и возрастает влияние «шума». На практике это затрудняет настройку параметров алгоритмов данного типа и не позволяет качественно выделять кластеры, характеризующиеся сложными распределениями [28].

Для решения проблемы выбора масштаба сетки применяется два подхода: использование нескольких сеток (различных масштабов) и построение адаптивной сетки. В алгоритмах ASGC [87] и DGD [88] после первоначальной кластеризации введенная сеточная структура сдвигается на половину размера ячейки по каждой размерности, после чего осуществляется кластеризация по сдвинутой сетке. Для построения окончательного результата пересекающиеся кластеры, полученные на различных сетках, объединяются. Данный подход позволяет собрать излишне раздробленные кластеры, однако это может привести к нежелательному объединению близких кластеров. Алгоритм NewSG [89] для оценки плотности клетки использует «расширенную» клетку (большого размера). Это дает более сглаженную оценку плотности и позволяет уменьшить раздробленность кластеров в случае мелкой сетки.

Часть алгоритмов настраивают масштаб сетки локально, адаптивно измельчая сетку в плотных областях. Например, алгоритм AMR [90], начиная с некоторой начальной сетки, рекурсивно разделяет клетки (пополам по каждой размерности), превышающие заданный порог плотности. При этом происходит построение так называемого AMR-дерева ограниченной высоты. Кластеры (вершины графа) могут быть отделены друг от друга, если существует такой уровень в дереве, на котором они разделяются неплотными клетками. При переходе на более высокий уровень дерева непомеченные клетки относятся к ближайшему из имеющихся кластеров. Алгоритм AMR позволяет выделять одномодовые кластеры различных масштабов.

Другие алгоритмы рекурсивно разбивают пространство признаков на клетки, пока количество элементов в клетках превосходит заданный порог [82, 91, 92]. Известным представителем такого подхода является алгоритм STING [93], в котором клетки характеризуются не только плотностью, но и векторами средних, минимальных и максимальных значений, дисперсией и типом статистического распределения.

Алгоритмы, основанные на построении полностью адаптивной сетки, выбирают положение гиперплоскостей сеточной структуры на основе анализа исходных данных.

Например, в алгоритме GRIDCLUS [86] гиперплоскости сеточной структуры строятся на основе медианной оценки так, чтобы разделить плотные клетки на приблизительно одинаковое число представителей данных. Дальнейшее построение кластеров происходит методом восхождения на вершину.

Алгоритмы MAFA [94] и OptiGrid [95] разработаны для кластеризации данных высокой размерности. Они осуществляют построение гиперплоскостей на основе анализа гистограмм в одномерных проекциях данных. Алгоритм MAFA находит места значительного скачка плотности на одномерной гистограмме, а OptiGrid выбирает места с минимальной плотностью. Эти методы позволяют обрабатывать многомерные данные, но при анализе проекций некоторые кластеры могут не разделяться. Кроме того, результаты их работы в значительной степени зависят от настройки параметров [28].

Существуют алгоритмы, использующие не прямоугольную сетку [96, 97]. В этом случае клетки имеют форму многогранников. Данные алгоритмы чувствительны к изменению параметров и требуют больших вычислительных затрат.

Таким образом, сеточные алгоритмы кластеризации обладают высоким быстродействием и способны выделять кластеры сложной формы, что делает их привлекательными для применения к спутниковым изображениям. Наиболее эффективными являются методы, основанные на комбинации плотностного и сеточного подходов. Однако существующие алгоритмы используют либо процедуру восхождения на вершину (выделяя только одномодовые кластеры), либо обнаруживают локальные скачки плотности (что позволяет выделять многомодовые кластеры, но затрудняет выделение пересекающихся кластеров). В связи с этим требуется разработать новые критерии выделения кластеров в рамках сеточного и плотностного подходов.

1.2.7. Ансамблевые алгоритмы кластеризации

В последние годы активно развивается направление кластеризации, связанное с применением ансамблевого подхода [13, 32, 56, 57, 98-104]. Ансамблевый подход заключается в создании нескольких вариантов разбиения данных и дальнейшем формировании согласованного результата кластеризации. Было показано [32, 98, 99, 101], что комбинирование различных кластерных решений позволяет повысить качество результатов и их устойчивость к изменению параметров.

При построении ансамблевого алгоритма кластеризации требуется решить два ключевых вопроса: как получить разнообразные разбиения, и каким образом сочетать эти разбиения.

Существует четыре основных способа получения начальных разбиений [98]:

- использование различных алгоритмов кластеризации [32];
- использование некоторого алгоритма кластеризации с разными параметрами [99];
- выбор различных подмножеств признаков [102];
- использование различных подмножеств данных [56].

Сочетание различных результатов кластеризации является трудной задачей, т.к. при необучаемой классификации возникает проблема установления соответствия меток кластеров [98]. Оптимальный комбинированный результат может быть получен путем нахождения «среднего разбиения» (median partition), то есть разбиения, минимизирующего сумму расстояний (различий) до всех разбиений кластерного ансамбля. Доказано, что эта задача является NP-трудной [105]. Поэтому на практике используются другие методы, такие как разделение гиперграфа, голосование, максимизация взаимной информации и согласованная матрица попарного сходства.

Графовые методы построения ансамблевых решений строят гиперграф, вершинами которого являются элементы данных, а ребрами соединяются элементы, принадлежащие одному кластеру, на каждом из разбиений [57, 99]. Задача поиска итогового разбиения сводится к оптимальному разделению вершин графа на заданное число подмножеств (кластеров) и решается методами спектральной кластеризации.

Ансамблевый подход на основе голосования устанавливает наиболее согласованное соответствие меток кластеров для использования процедуры голосования [13]. При этом требуется, чтобы количество кластеров совпадало во всех разбиениях.

Методы на основе максимизации взаимной информации (mutual information) [102] строят коллективное решение, максимизируя сумму мер взаимной информации искомого варианта кластеризации со всеми исходными разбиениями.

Одним из наиболее эффективных методов построения ансамблевого решения является использование согласованной матрицы попарного сходства/различия (co-association matrix) [103]. Элементы матрицы характеризуют попарную схожесть объектов как количество разбиений, в которых эти объекты относятся к одному кластеру. Для получения согласованного решения матрица сходства используется как

матрица расстояний между объектами, и к ней применяется один из стандартных иерархических алгоритмов кластеризации (например, метод ближайшего соседа).

Таким образом, использование ансамблевого подхода позволяет повысить устойчивость и качество получаемых результатов кластеризации. Однако большинство существующих методов являются вычислительно трудоемкими [32, 56], поэтому в настоящее время активно ведутся исследования по увеличению их быстродействия [99].

1.3. Методы спектрально-текстурной сегментации изображений

В ряде случаев использования только спектральных или только текстурных характеристик недостаточно для качественной сегментации изображения. Поэтому проблема совместного использования спектральных и текстурных признаков является одним из активно развиваемых направлений исследований в области компьютерного зрения [106]. Данная задача осложняется присутствием на изображениях неравномерного освещения, «шума», а также существенных неоднородностей цвета и текстуры.

В зависимости от подходов, используемых для извлечения и интеграции спектральных (цветовых) и текстурных признаков, выделяются три основных направления: (1) методы на основе последовательного извлечения спектральных и текстурных характеристик, (2) методы на основе независимого извлечения характеристик и (3) вероятно-статистические методы.

Первое направление основывается на последовательном извлечении спектральных и текстурных характеристик. Этот подход оказался успешным в практическом плане, хотя он имеет ряд недостатков. Признаки, которые извлекаются первыми, имеют более высокий вес в общем процессе сегментации. Кроме того, алгоритмы цветотекстурной сегментации изображений, относящиеся к этому направлению, зачастую требуют оптимизации большого числа параметров, что затрудняет их практическое применение в задачах сегментации изображений [106].

Наиболее известным представителем данной группы является алгоритм JSEG [107], который часто используется в качестве эталона для сравнения спектрально-текстурных алгоритмов сегментации. Алгоритм состоит из трех основных этапов. Сначала производится адаптивное квантование (на 10-20 уровней). Затем формируется так называемое J-изображение (J-image), которое характеризует локальную однородность в зависимости от степени равномерности распределения цветовых меток в

окрестности каждого пикселя. Данный показатель используется как индикатор границ кластеров. На третьем этапе из полученного J-изображения методом наращивания областей выделяются кластеры. Полученные близкие по цвету соседние сегменты могут дополнительно объединяться.

Недостатком алгоритма JSEG является неустойчивость к возможным неоднородностям распределения цвета и текстуры на изображении, что нередко приводит к пересегментации. В работе [108] предлагается модификация алгоритма JSEG, в которой на первом этапе вместо квантования цветов применяется кластеризация алгоритмом Mean shift, что помогает справляться с неоднородным распределением цвета. В работе [109] предлагается алгоритм T-JSEG, который дополнительно производит кластеризацию по текстурным признакам, используя на втором этапе метки текстурных классов наряду с цветовыми метками. Однако предложенные модификации не дают существенного улучшения качества сегментации и также характеризуются пересегментацией [106]. Кроме того, они значительно увеличивают вычислительные затраты.

Другим примером последовательного извлечения признаков является алгоритм SCKM [110]. На первом этапе работы для каждого пикселя вычисляется трехмерная гистограмма цветов (5^3 элементов) в его квадратной окрестности, и производится кластеризация гистограмм алгоритмом К-средних на 5 кластеров. С помощью такого подхода, изображение разбивается на множество сегментов. На втором этапе цвета пикселей заменяются средними значениями по сегментам, и выполняется кластеризация пространственным алгоритмом К-средних (spatially-constrained K-means). Авторы отмечают, что алгоритм требует тщательной настройки параметров. При этом время работы составляет 20 с для изображений размера 320×200 , что сравнимо со многими другими цвето-текстурными алгоритмами сегментации (использовался процессор AMD Athlon 64 3500+, 2.2 ГГц) [110].

Второе направление методов спектрально-текстурной сегментации основывается на независимом извлечении спектральных и текстурных характеристик, при этом интеграция признаков осуществляется с использованием пространственной информации (region-based). Алгоритмы, принадлежащие к этой категории, можно разделить на три подгруппы: разделения и слияния, наращивания областей и активных контуров.

Алгоритмы разделения и слияния (split and merge) [111-113] осуществляют рекурсивное разделение изображения на сегменты (как правило, квадратные) до тех пор, пока

выполняется критерий неоднородности или не достигается предельная глубина разбиения. На втором этапе соседние сегменты объединяются, если расстояние между ними не превышает заданного порога. Расстояние между сегментами определяется как сумма расстояний по спектральным и по текстурным признакам с заданными весами. Многие алгоритмы используют адаптивное определение весов: чем область более однородна (по цвету), тем больше вклад спектральных/цветовых характеристик. На заключительном этапе производится попиксельная коррекция границ полученных сегментов [114]. Переход к работе с фрагментами изображения позволяет достичь высокого быстродействия, поэтому именно на этом подходе основаны многие алгоритмы спектрально-текстурной сегментации спутниковых изображений [114-117]. Важным параметром алгоритмов разделения и слияния является минимальный размер сегмента. Слишком малое его значение приводит к пересегментации. Напротив, если его значение слишком велико, возникают пропуски небольших объектов и снижается точность сегментации.

Алгоритмы разделения и слияния, работающие по описанной схеме, представлены в работах [111, 112]. В качестве текстурных признаков в них используются локальные бинарные шаблоны (Local Binary Pattern), а в качестве спектральных – гистограммы меток цветовых классов, полученных самоинициализирующимся алгоритмом кластеризации ЕМ [111] или алгоритмом К-средних [112] (задавалось разбиение на 10 классов).

Алгоритмы наращивания областей (region growing) позволяют более точно обнаруживать границы кластеров. Они начинают работу с выбора исходных «семян», к которым итеративно присоединяются соседние пиксели на основе некоторого критерия однородности [4]. Основным недостатком этого подхода является сильная зависимость результатов сегментации от выбора «семян» и оптимального выбора набора пороговых параметров [9]. В результате, алгоритмы наращивания областей испытывают трудности, связанные с наличием «шума», теней и неравномерного освещения [5].

Алгоритмы на основе активных контуров производят итеративную деформацию некоторого начального контура с помощью минимизации энергии, которая связана с внутренними свойствами контура. Например, функция энергии может соответствовать вероятности того, что текущие граничные пиксели являются граничными, в то время как выделенные области являются внутренне однородными. Алгоритмы на основе активных контуров обеспечивают высокую точность получаемых границ. Однако результаты сегментации зависят от выбора начального контура и числа классов [118]. Кроме того,

данные алгоритмы состоят из вычислительно затратных итерационных процедур, что затрудняет их применение к спутниковым изображениям [9].

Третье направление методов спектрально-текстурной сегментации также основывается на независимом извлечении спектральных и текстурных характеристик, но интеграция признаков осуществляется в рамках вероятностно-статистического подхода. Алгоритмы, принадлежащие данному подходу, рассматривают данные в едином спектрально-текстурном пространстве, в котором применяются известные алгоритмы кластеризации (обобщенный алгоритм К-средних, ЕМ, алгоритмы нечеткой кластеризации, нейронные сети). Преимуществом данного подхода является одновременный анализ всего изображения. Однако данный подход имеет ряд недостатков: многие алгоритмы требуют задания числа кластеров, не способны адаптироваться к локальным искажениям и характеризуются большими вычислительными затратами [106].

Самый известный представитель данного направления – алгоритм СТех [119]. Извлечение цветовых признаков осуществляется на основе кластеризации самоорганизующимися картами Кохонена (SOM). В качестве текстурных характеристик используются фильтры Габора. Интеграция текстурных и цветовых признаков осуществляется с помощью кластеризации пикселей в едином цвето-текстурном пространстве обобщенным алгоритмом К-средних (Adaptive Spatial K-Means). Алгоритм СТех позволяет получить достаточно качественные результаты сегментации изображений, но обладает очень высокой вычислительной трудоемкостью [110].

В работе [118] в единый вектор признаков собираются значения цветовых характеристик (RGB), набор текстурных признаков (multi-scale structure tensor) и локальные характеристики (total variation flow). Все значения приводятся к диапазону [0, 255]. Комбинированные векторы признаков кластеризуются параметрическим алгоритмом на основе модели смеси распределений Стюдента. Полученные в результате кластеризации изображения смежные сегменты дополнительно объединяются с помощью критерия на основе цвета, текстуры, размера и наличия общей границы сегментов. Данный алгоритм производит качественные результаты сегментации, однако имеет высокую вычислительную сложность. Указанное авторами время работы составляет 128 с для изображений размера 320×214 пикселей (использовался процессор Intel Core2Duo T5450, 1.66 ГГц).

Несмотря на большое число разработанных алгоритмов сегментации изображений на основе совместного использования спектральных и текстурных признаков, их применение к мультиспектральным спутниковым снимкам затруднено из-за особенностей задачи [117]: большой размер изображений, множество спектральных каналов, наличие большого числа различных объектов на снимке. На данный момент лишь небольшое количество исследований было посвящено задаче сегментации спутниковых изображений с использованием спектрально-текстурных характеристик [9, 114-117, 120, 121].

Наиболее распространенным является использование метода разделения и слияния [114-117]. Во многом это связано с низкой трудоемкостью данного метода. Во всех представленных алгоритмах в качестве текстурных признаков используются локальные бинарные шаблоны (Local Binary Pattern, LBP).

В работе [114] расстояние между сегментами определяется с помощью трех характеристик, вес которых определяется автоматически: яркость, текстура и цвет. Причем в качестве цветовой характеристики выступает двумерная гистограмма тона и насыщенности. Метод применялся к спутниковому изображению QuickBird размера 512×512 пикселей. Представленный алгоритм не учитывает мультиспектральную информацию спутниковых данных, что значительно ограничивает возможности качественной сегментации.

Алгоритм, представленный в [115], осуществляет построение двумерных спектральных и текстурных гистограмм с помощью метода главных компонент. Алгоритм применялся для сегментации мультиспектральных снимков IKONOS и QuickBird размера 256×256 пикселей. В работе отмечается, что параметры текстурных признаков оказывают сильное влияние на результат сегментации.

В работе [116] метод разделения и слияния применяется без использования стандартных текстурных характеристик. В качестве признаков использовалась гистограмма меток кластеров, полученных с помощью нечеткого алгоритма кластеризации Fuzzy ART. Данный метод применялся к мультиспектральному спутниковому изображению QuickBird размера 512×512 пикселей.

Алгоритм [117] на этапе разделения производит сегментацию изображения с помощью алгоритма водораздела. При пороговом объединении соседних сегментов учитываются их размеры. В качестве расстояния используются расстояния между гистограммами цвета и текстуры с адаптивно определяемыми весами. Алгоритм исполь-

зовался для сегментации спутниковых снимков QuickBird и SPOT-5 размера 400×400 пикселей. Приведенное время обработки изображений составляет 1 с, в то время как алгоритму JSEG требуется 10 с (использовался процессор Intel Core i5, 2.4 ГГц).

В литературе представлено несколько спектрально-текстурных алгоритмов сегментации спутниковых изображений, основанных на вероятностно-статистическом подходе [120, 121]. В работе [120] каждый пиксель характеризуется вектором признаков, состоящим из локальных гистограмм фильтров Габора, лапласиана (LoG) и яркости, вычисленных для каждого спектрального канала. Пиксели изображения рассматриваются как линейные комбинации представителей классов, и относятся к наиболее похожему представителю. Представители могут быть выбраны вручную или найдены автоматически с помощью кластеризации алгоритмом К-средних в подпространстве признаков, однако в этом случае требуется задание количества кластеров. Описанный алгоритм применялся к мультиспектральному изображению IKONOS размера 501×501 пиксель, при этом для сокращения вычислений фильтры Габора и лапласиана считались только для одного канала панхроматического изображения. В результате было выделено 5 классов: дороги, парковки, здания, деревья и трава. Время обработки снимка составило 150 с (использовался процессор Intel, 2.6 ГГц). Авторы отмечают, что качество сегментации снижается при попытке выделения большого числа классов на сложных сценах.

Алгоритм [121] в качестве признаков использует фильтры Габора и значения спектральных яркостей. Выполняется кластеризация пикселей в едином пространстве признаков с помощью самоорганизующейся карты Кохонена на 40 кластеров. Затем полученные представители кластеров итеративно объединяются иерархическим алгоритмом (CONN linkage) до получения заданного числа классов (авторы задавали 10 классов). Алгоритм использовался для выделения виноградников на мультиспектральном изображении SPOT-5 с разрешением 2.5 м размера приблизительно 1000×1000 пикселей. На результате сегментации хорошо заметны артефакты от дорог, разделяющих поля.

В отличие от методов разделения и слияния, использование вероятностно-статистического подхода позволяет анализировать признаки глобально для всего изображения, что важно для больших сцен. Однако этот подход не учитывает взаимное расположение пикселей на изображении, что снижает робастность сегментации из-за значительной локальной изменчивости спектрально-текстурных характеристик.

Проведенное исследование показало, что в настоящее время отсутствуют вычислительно эффективные алгоритмы спектрально-текстурной сегментации мультиспектральных спутниковых изображений. В опубликованных результатах исследований спектрально-текстурных алгоритмов сегментации не демонстрируется способность обрабатывать мультиспектральные изображения большого размера и возможность выделения похожих текстурных классов, таких как различные типы леса.

1.4. Краткие выводы по главе

1. Дана содержательная постановка задачи сегментации изображений. Указаны особенности обработки спутниковых изображений высокого пространственного разрешения и сформулированы требования к алгоритмам сегментации таких изображений.
2. Проведен анализ известных алгоритмов кластеризации. Выявлены достоинства и недостатки этих алгоритмов применительно к задаче сегментации спутниковых изображений. Известные непараметрические алгоритмы, обеспечивающие выделение кластеров сложной структуры (разной формы, размера и плотности), характеризуются высокой вычислительной трудоемкостью. Преимуществом иерархических алгоритмов является удобство интерпретации результатов, однако они не позволяют разделять пересекающиеся кластеры и характеризуются высокой вычислительной трудоемкостью. Наиболее перспективными для сегментации мультиспектральных изображений высокого пространственного разрешения являются сеточные алгоритмы кластеризации, т.к. они позволяют выделять кластеры сложной структуры и обладают высоким быстродействием. Однако их результаты неустойчивы к изменению параметров сетки. Кроме того, они не позволяют выделять многомодовые пересекающиеся кластеры.
3. Дан обзор известных алгоритмов спектрально-текстурной сегментации изображений. В настоящее время существует всего несколько алгоритмов сегментации спутниковых данных, учитывающих мультиспектральную текстуру. При этом отсутствуют вычислительно эффективные алгоритмы, обеспечивающие высокое качество при сегментации мультиспектральных спутниковых изображений высокого пространственного разрешения.

Глава 2. Алгоритмы кластеризации мультиспектральных изображений на основе сеточного и ансамблевого подходов

В данной главе предлагаются новые непараметрические алгоритмы кластеризации ССА и ЕССА для сегментации мультиспектральных спутниковых изображений, разработанные в рамках комбинации плотностного и сеточного подходов.

2.1. Формальная постановка задачи кластеризации в рамках сеточного подхода

Для описания предлагаемых алгоритмов введем необходимые определения.

Пусть множество классифицируемых объектов X состоит из векторов, лежащих в d -мерном пространстве признаков $\mathbb{R}^d$: $X = \{x_i = (x_i^{(1)}, \dots, x_i^{(d)}) \in \mathbb{R}^d, i = \overline{1, N}\}$. Векторы x_i ограничены прямоугольным гиперпараллелепипедом $\Omega = [l^{(1)}, r^{(1)}] \times \dots \times [l^{(d)}, r^{(d)}]$, где $l^{(j)} = \min_{x_i \in X} x_i^{(j)}$, $r^{(j)} = \max_{x_i \in X} x_i^{(j)}$.

Определение 2.1. Под *сеточной структурой* будем понимать разбиение пространства признаков гиперплоскостями: $x^{(j)} = (r^{(j)} - l^{(j)}) \cdot i/m + l^{(j)}$, $i = 0, \dots, m$, где m – число разбиений Ω по каждой размерности. Минимальным элементом этой структуры является *клетка* (замкнутый прямоугольный гиперпараллелепипед, ограниченный гиперплоскостями). Введем общую нумерацию клеток (последовательно от одного слоя клеток к другому). Клетки B_i и B_j ($i \neq j$) являются *смежными*, если их пересечение не пусто. Множество смежных с B клеток обозначим через A_B .

Определение 2.2. *Плотностью* D_B клетки B назовем отношение $D_B = N_B/V_B$, где N_B – количество элементов множества X , попавших в клетку B ; V_B – объем клетки B . Клетку B будем считать *непустой*, если $D_B > 0$.

Определение 2.3. Непустая клетка B_i *непосредственно связна* с непустой клеткой B_j ($B_i \rightarrow B_j$), если B_j – максимальная по номеру клетка, удовлетворяющая условиям: $B_j = \arg \max_{B_k \in A_{B_i}} D_{B_k}$ и $D_{B_j} \geq D_{B_i}$. Непустые клетки B_i и B_j *непосредственно связны* ($B_i \leftrightarrow B_j$), если $B_i \rightarrow B_j$ или $B_j \rightarrow B_i$. Непустые клетки B_i и B_j *связны* ($B_i \sim B_j$), если существуют $k_1, \dots, k_l$ такие, что $k_1 = i$, $k_l = j$ и для всех $p = 1, \dots, l-1$ выполнено $B_{k_p} \leftrightarrow B_{k_{p+1}}$. В частности, выполнено свойство рефлексивности: $\forall i B_i \sim B_i$.

Утверждение 2.1. Отношение связности клеток является отношением эквивалентности.

Доказательство. Симметричность и рефлексивность выполняются по определению. Покажем транзитивность отношения связности. Пусть имеются клетки B_i , B_j и B_k такие, что $B_i \sim B_j$ и $B_j \sim B_k$. По определению существуют последовательности клеток $m_1, \dots, m_r$, где $m_1 = i$, $m_r = j$, и $t_1, \dots, t_s$, где $t_1 = j$, $t_s = k$, такие, что $B_{m_p} \leftrightarrow B_{m_{p+1}}$ для всех $p = 1, \dots, r-1$ и $B_{t_p} \leftrightarrow B_{t_{p+1}}$ для всех $p = 1, \dots, s-1$. Таким образом, для последовательности клеток $m_1, \dots, m_r, t_2, \dots, t_s$ выполняется непосредственная связность всех пар соседних клеток, следовательно $B_i \sim B_k$. ■

Введение отношения связности порождает естественное разбиение множества непустых клеток на классы эквивалентности (*компоненты связности*) $\{G_1, \dots, G_S\}$.

Определение 2.4. Под *компонентой связности* будем понимать максимальное множество попарно связных клеток. Компоненты связности G' и G'' *смежны*, если существуют смежные клетки B' и B'' такие, что $B' \in G'$ и $B'' \in G''$.

Определение 2.5. *Представителем компоненты связности G* назовем максимальную по номеру клетку $Y(G)$, удовлетворяющую условию: $Y(G) = \arg \max_{B \in G} D_B$.

Выделенные компоненты связности соответствуют одномодовым кластерам, а их представители – модам плотности этих кластеров.

Определение 2.6. Смежные компоненты связности G_i , G_j *непосредственно связны* ($G_i \leftrightarrow G_j$), если существует набор клеток $P_{ij} = \{Y(G_i) = B_{k_1}, \dots, B_{k_t}, B_{k_{t+1}}, \dots, B_{k_l} = Y(G_j)\}$ такой, что: 1) для всех $t = 1, \dots, l-1$ клетка $B_{k_t} \in G_i \cup G_j$ и $B_{k_t}, B_{k_{t+1}}$ – смежные клетки; 2) $\min_{B_{k_t} \in P_{ij}} D_{B_{k_t}} / \min(D_{Y(G_i)}, D_{Y(G_j)}) > T$, где $T \in [0; 1]$ – *порог объединения*. Компоненты связности G_i и G_j *связны* ($G_i \sim G_j$), если существуют $k_1, \dots, k_l$ такие, что $k_1 = i$, $k_l = j$ и для всех $p = 1, \dots, l-1$ выполнено $G_{k_p} \leftrightarrow G_{k_{p+1}}$.

Определение 2.7. *Кластером C* назовем максимальное множество попарно связных компонент связности, то есть: 1) для любых компонент связности $G_i, G_j \in C$ выполнено $G_i \sim G_j$; 2) для любых $G_i \in C$, $G_j \notin C$ верно $G_i \not\sim G_j$.

Таким образом, формальную постановку задачи кластеризации в рамках сеточного подхода можно сформулировать следующим образом. Требуется разделить введен-

ную в пространстве признаков сеточную структуру (клетки) на кластеры и распределить элементы исходных данных по кластерам, к которым отнесены содержащие их клетки.

2.2. Сеточный алгоритм кластеризации ССА

Предлагаемый алгоритм $ССА(m, T)$, где m – параметр масштаба сетки, T – порог объединения компонент связности, позволяет выделять кластеры в соответствии с определением 2.7.

Входными данными являются N классифицируемых d -мерных векторов и параметры m и T . Алгоритм ССА состоит из шести шагов, выполняемых последовательно.

Шаг 1. Формирование многомерной гистограммы. Создается массив, элементами которого являются плотности клеток, инициализированный нулевыми значениями $\{D_{B_i} = 0, i = \overline{1, m^d}\}$. Для каждого вектора данных вычисляется и запоминается номер клетки, в которую он попадает $\{Cell[x_i], i = \overline{1, N}\}$. При этом плотность этой клетки увеличивается на единицу.

Псевдокод шага 1:

$FOR (i = \overline{1, N}): D_{Cell[x_i]} = D_{Cell[x_i]} + 1;$

Шаг 2. Формирование массива ссылок для непосредственно связанных клеток $\{Link[B_i], i = \overline{1, m^d}\}$. Для каждой непустой клетки среди смежных с ней клеток и ее самой выбирается максимальная по номеру клетка, плотность которой не меньше плотности остальных рассматриваемых клеток. В формируемый массив заносится ссылка на выбранную клетку. На данном этапе также определяются представители компонент связности $\{Y(G_1), \dots, Y(G_s)\}$, как клетки со ссылками на самих себя.

Псевдокод шага 2:

$\{Y(G_i)\} = \emptyset;$

$FOR (i: D_{B_i} > 0) \left\{ \begin{array}{l} Link[B_i] = \max_k \arg \max_{B_k \in (B_i \cup A_{B_i})} D_{B_k}; \\ IF (Link[B_i] = B_i): B_i \rightarrow \{Y(G_i)\}; \end{array} \right\}$

Шаг 3. Выделение компонент связности. Создается массив, содержащий компоненты связности для каждой клетки и инициализированный нулевыми значениями $\{Comp[B_i] = 0, i = \overline{1, m^d}\}$. Для каждой непустой нерассмотренной клетки осуществляется последовательный переход по ссылкам к непосредственно связным клеткам вплоть

до достижения клетки-представителя компоненты или уже рассмотренной клетки. Затем все клетки пройденной цепочки относятся к соответствующей компоненте связности.

Псевдокод шага 3:

$FOR (i = \overline{1, s}): Comp[Y(G_i)] = G_i;$

$$FOR (i: D_{B_i} > 0, Comp[B_i] = 0) \left\{ \begin{array}{l} B = B_i; \{Q\} = \{B\}; \\ WHILE (Comp[B] = 0): \{B = Link[B_i]; B \rightarrow \{Q\}\}; \\ FOR (B_j \in Q): Comp[B_j] = Comp[B]; \end{array} \right\}$$

Шаг 4. Формирование матрицы связей между смежными компонентами связности. Изначально все связи отсутствуют $\{CompLink[G_i, G_j] = FALSE, i, j = \overline{1, s}\}$. Среди всех пар непустых смежных клеток рассматриваются только те, которые принадлежат к разным компонентам связности (граничные). Для рассматриваемой пары клеток $B_i \in G_k, B_j \in G_l (G_k \neq G_l)$ и клеток-представителей соответствующих компонент связности $Y(G_k), Y(G_l)$ проверяется выполнение критерия объединения: $\min(D_{B_i}, D_{B_j}) / \min(D_{Y(G_k)}, D_{Y(G_l)}) > T$. Если критерий выполняется, то данные компоненты связности помечаются непосредственно связными.

Псевдокод шага 4:

$$FOR \left(\begin{array}{l} i, j: D_{B_i} > 0, D_{B_j} > 0, \\ B_j \in A_{B_i}, Comp[B_i] \neq Comp[B_j] \end{array} \right) \left\{ \begin{array}{l} G_k = Comp[B_i]; G_l = Comp[B_j]; \\ IF \left(\min(D_{B_i}, D_{B_j}) / \min(D_{Y(G_k)}, D_{Y(G_l)}) > T \right): \\ \quad CompLink[G_i, G_j] = TRUE; \end{array} \right\}$$

Шаг 5. Объединение непосредственно связанных компонент в кластеры. Создается массив для определения кластера по компоненте связности, инициализированный нулевыми значениями $\{Cluster[G_i] = 0, i = \overline{1, s}\}$. Начиная с каждой нерассмотренной компоненты, рекурсивно обходятся все компоненты, непосредственно связанные с текущей. При этом просмотренные компоненты относятся к новому кластеру.

Псевдокод шага 5:

$num = 1;$

$FOR (i: Cluster[G_i] = 0) \{Cluster[G_i] = num; LINK(G_i, num); num = num + 1;\}$

$$LINK(G_i, class): \left\{ \begin{array}{l} FOR (j: CompLink[G_i, G_j] = TRUE, Cluster[G_j] = 0) \\ \quad \{Cluster[G_j] = class; LINK(G_j, class);\} \end{array} \right\}$$

Шаг 6. На заключительном этапе алгоритма элементы исходных данных распределяются по кластерам $\{Cl[x_i], i = \overline{1, N}\}$, к которым отнесены содержащие их клетки.

Псевдокод шага 6:

FOR ($i = \overline{1, N}$): $Cl[x_i] = Cluster[Comp[Cell[x_i]]]$;

Иллюстрация работы алгоритма ССА. На рисунке 2.1 приведена схема работы алгоритма ССА на модели двумерных данных, состоящей из 900 точек (рисунок 2.1,а). Задавались следующие параметры алгоритма: $m = 20, T = 0.2$.




Рисунок. 2.1 – Схема работы алгоритма ССА на примере модели двумерных данных:

(а) исходные данные; (б) результат введения сеточной структуры в двумерном пространстве признаков; (в) визуализация оценки плотности распределения, вычисленная на клетках сеточной структуры; (г) результат формирования компонент связности; (д) иллюстрация выполнения критерия непосредственной связности двух смежных компонент и график плотности клеток в отмеченной черной жирной линией цепочке; (е) окончательный результат кластеризации

Сформированная сеточная структура показана на рисунке 2.1,б. Визуализация оценки плотности представлена на рисунке 2.1,в. В результате выполнения первых трех

шагов алгоритма были выделены 23 компоненты связности, которые обозначены на рисунке 2.1,г разными цветами, а их клетки-представители отмечены белыми кругами. На рисунке 2.1,д демонстрируется проверка критерия непосредственной связности двух смежных компонент связности. Указаны представители рассматриваемых компонент связности Y_1, Y_2 и смежные граничные клетки B', B'' , для которых выполняется критерий объединения компонент связности.

$$\frac{\min(D_{B'}, D_{B''})}{\min(D_{Y_1}, D_{Y_2})} = \frac{\min(7, 4)}{\min(10, 11)} = \frac{4}{10} > T = 0.2.$$

Также, на рисунке 2.1,д черной жирной линией отмечена цепочка клеток $\{Y_1, \dots, B', B'', \dots, Y_2\}$, для которой выполняется критерий непосредственной связности смежных компонент, и приведен график плотности клеток в этой цепочке. В результате объединения связных компонент на шаге 5 сформировано 3 кластера (рисунок 2.1,е).

Утверждение 2.2. В результате работы алгоритма ССА выделяются кластеры в соответствии определением 2.7.

Доказательство. Формирование сеточной структуры, подсчет плотностей клеток и определение непосредственно связных клеток осуществляется в соответствии определениями 2.1-2.3. На шаге 3 все непосредственно связные пары клеток относятся к одной компоненте связности, а значит, и любая цепочка непосредственно связных клеток будет принадлежать одной компоненте связности.

Корректность нахождения клеток-представителей компонент связности обеспечивается тем, что, согласно построению, для каждой клетки $B \in G$ существует цепочка клеток $B = B_{k_1}, \dots, B_{k_s} = Y(G)$, в которой для всех $p = 1, \dots, s - 1$ выполнено неравенство $D_{B_{k_p}} \leq D_{B_{k_{p+1}}}$. Следовательно, плотность клетки-представителя $D_{Y(G)}$ является максимальной среди всех клеток, принадлежащих компоненте связности G . При наличии нескольких клеток с максимальным значением плотности, в качестве представителя компоненты связности по построению выбирается клетка с максимальным номером.

На шаге 4 смежные компоненты связности G_i и G_j помечаются непосредственно связными, если существуют такие смежные клетки $B_s \in G_i$, $B_l \in G_j$, что $\min(D_{B_s}, D_{B_l}) / \min(D_{Y(G_i)}, D_{Y(G_j)}) > T$. Пусть выполнен данный критерий. По построению существует цепочки клеток $B_s = B_{k_1}, \dots, B_{k_r} = Y(G_i)$ и $B_l = B_{t_1}, \dots, B_{t_m} = Y(G_j)$, в которых для всех $p = 1, \dots, r - 1$ выполнено неравенство $D_{B_{k_p}} \leq D_{B_{k_{p+1}}}$ и для всех

$p = 1, \dots, m - 1$ выполнено неравенство $D_{B_{t_p}} \leq D_{B_{t_{p+1}}}$. Следовательно, для цепочки $P_{ij} = \{Y(G_i) = B_{k_r}, \dots, B_{k_1} = B_s, B_l = B_{t_1}, \dots, B_{t_m} = Y(G_j)\}$ выполняется равенство $\min_{B \in P_{ij}} D_B = \min(D_{B_s}, D_{B_l})$. Таким образом, эта цепочка удовлетворяет определению непосредственной связности компонент $(G_i \leftrightarrow G_j)$.

Докажем обратное. Пусть $G_i \leftrightarrow G_j$. По определению 2.6 существует цепочка клеток $P_{ij} = \{Y(G_i) = B_{k_1}, \dots, B_{k_m} = Y(G_j)\}$, $P_{ij} \in G_i \cup G_j$ такая, что $\min_{B \in P_{ij}} D_B / \min(D_{Y(G_i)}, D_{Y(G_j)}) > T$. В цепочке P_{ij} имеется пара смежных клеток $(B_s \in G_i, B_l \in G_j)$. Следовательно

$$\frac{\min(D_{B_s}, D_{B_l})}{\min(D_{Y(G_i)}, D_{Y(G_j)})} \geq \frac{\min_{B \in P_{ij}} D_B}{\min(D_{Y(G_i)}, D_{Y(G_j)})} > T.$$

Таким образом, все непосредственно связные компоненты связности будут найдены на шаге 4.

Объединение непосредственно связных компонент в кластеры на шаге 5 происходит в соответствии с определением 2.7. ■

Оценка вычислительной сложности алгоритма ССА.

Представленный алгоритм $ССА(m, T)$ является вычислительно эффективным в пространстве признаков при небольшой размерности ($d \leq 5$). Вычислительная сложность первого шага составляет $\mathcal{O}(N \cdot d + m^d)$. На втором шаге для каждой клетки сеточной структуры обрабатываются смежные с ней клетки, поэтому вычислительная сложность данного этапа не превышает $\mathcal{O}(m^d \cdot 3^d)$. Сложность последующих этапов работы алгоритма (шаги 3-5) ограничена числом клеток $\mathcal{O}(m^d)$. На завершающем шаге требуется $\mathcal{O}(N)$ операций. Соответственно, вычислительная сложность алгоритма при ограниченной размерности данных d составляет $\mathcal{O}(N + m^d)$. Для мультиспектральных спутниковых изображений можно считать, что $d < 20$. Таким образом, вычислительная трудоемкость линейно зависит от числа объектов, что позволяет обрабатывать большие массивы данных (порядка 10^8 элементов).

Высокая вычислительная эффективность алгоритма обеспечивается переходом от обработки элементов данных к элементам сеточной структуры. Однако это преимущество теряется при высоких размерностях пространства признаков ($d \geq 6$) из-за больших затрат памяти на хранение сеточной структуры. Например, при $d = 5$ и $m = 32$

количество клеток в сеточной структуре составляет 33 554 432, а при $m = 40$ – уже более 100 миллионов, что значительно превосходит число пикселей большинства мультиспектральных спутниковых изображений. Экспоненциальная зависимость необходимого объема памяти от размерности пространства признаков затрудняет обработку мультиспектральных изображений, содержащих более 5 каналов.

Для снижения трудоемкости при высокой размерности пространства признаков была разработана модификация алгоритма, позволяющая хранить только непустые клетки, число которых не может превосходить N . Для обращения к произвольной клетке по ее координатам используется четырехмерная сеточная структура, позволяющая по первым четырем координатам получить список соответствующих непустых клеток. При этом среднее время доступа к клетке составляет $t = N/m^4$ операций. Например, для 10^7 элементов данных при $m = 32$ среднее время доступа составляет $t < 10$ операций. Таким образом, с помощью разработанного подхода была решена проблема высоких затрат памяти, что позволило реализовать алгоритм ССА для обработки данных достаточно высокой размерности (вплоть до $d = 8$).

2.3. Экспериментальное исследование алгоритма ССА

Предложенный алгоритм ССА исследован на модельных и реальных данных. Многочисленные эксперименты показали, что алгоритм при низких вычислительных затратах обеспечивает высокое качество результатов и способен выделять многомерные кластеры сложной структуры (формы, размера и плотности).

Определение 2.8. Если для рассматриваемых данных известна некоторая эталонная кластеризация $\{C_i^*\}_{i=1}^M$, то для произвольной кластеризации $\{C_i\}_{i=1}^K$ установим такое соответствие между кластерами $\gamma(i): \{C_1^*, \dots, C_M^*\} \rightarrow \{C_1, \dots, C_K, \emptyset\}$, чтобы $\forall(i \neq j): \gamma(i) = \gamma(j) \Leftrightarrow \gamma(i) = \emptyset$, и максимизировать выражение $n_\gamma = \sum_{i=1}^M |C_i^* \cap C_{\gamma(i)}|$. Тогда *точность кластеризации* определим следующим образом: $acc = n_\gamma/N$. А *ошибку кластеризации* определим по формуле

$$err = \frac{N - n_\gamma}{N} = 1 - acc.$$

Все представленные в диссертации методы и алгоритмы реализованы на языке программирования Java. Экспериментальные исследования проводились на ПЭВМ с четырехядерным процессором Intel Core i7, 3.2 ГГц.

На рисунках 2.2 и 2.3 представлены четыре модели данных, демонстрирующие различные типы кластеров.

Модель данных № 1. Модельные данные состоят из двух равновероятных классов в двумерном пространстве признаков. Первый класс описывается нормальным распределением с вектором математического ожидания $\mu = (128, 128)$ и ковариационной матрицей $\Sigma = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix}$, где $\sigma = 20$. Элементы второго класса равномерно распределены по кольцу с центром в точке $(128, 128)$ и радиусами $R_{min} = 80$, $R_{max} = 120$. Для модели генерировалось 200 точек первого и 400 точек второго классов (рисунок 2.2,а).

Модель данных № 2. Рассматривается популярная модель «бананы», построенная с помощью инструмента PRTOOLS [122]. Модель содержит два линейно неразделимых двумерных равновероятных класса, имеющих форму бананов. Элементы классов распределены равномерно по форме бананов и смещены по каждой координате на случайную величину, характеризующуюся нормальным распределением с математическим ожиданием $\mu = (0, 0)$ и среднеквадратичным отклонением $\sigma = 0.7$. Для данной модели генерировалось по 200 точек для каждого класса (рисунок 2.2,б).

Модель данных № 3. Рассматриваются три равновероятных класса в двумерном пространстве признаков. Первый класс описывается нормальным распределением с вектором математического ожидания $\mu = (0, 0)$ и ковариационной матрицей $\Sigma = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix}$, где $\sigma = 0.9$. Элементы второго класса равномерно распределены на отрезке $[-4; 6]$ по второму признаку, а значения первого признака определялись в соответствии с выражением: $x_1 = -\sqrt{25 - (x_2 - 1)^2} + \xi$, где ξ – случайная величина, имеющая равномерное распределение на отрезке $[-1.5; 1.5]$. Третий класс генерировался путем зеркального отражения точек второго класса относительно начала координат. Для данной модели генерировалось по 300 точек для каждого класса (рисунок 2.2,в).

Модель данных № 4. Модельные данные состоят из девяти равновероятных классов в трехмерном пространстве признаков. Первый класс описывается равномерным распределением в кубе $[95; 155] \times [155; 225] \times [10; 70]$, для него генерировалось 1000 точек. Для следующих четырех классов, имеющих нормальное распределение с векторами математического ожидания $\mu_2 = (120, 190, 105)$, $\mu_3 = (45, 45, 55)$, $\mu_4 = (45, 45, 125)$, $\mu_5 = (45, 45, 195)$ и одинаковыми ковариационными матрицами

$\Sigma = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix}$, где $\sigma = 15$, генерировалось по 800 точек. Для оставшихся четырех классов, также имеющих нормальное распределение с векторами математического ожидания $\mu_6 = (160, 45, 55)$, $\mu_7 = (200, 45, 55)$, $\mu_8 = (180, 80, 55)$, $\mu_9 = (180, 57, 88)$ и ковариационной матрицей $\Sigma = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix}$, где $\sigma = 10$, генерировалось по 600 точек. Последняя группа классов имеет значительные пересечения в пространстве признаков. Всего модель содержит из 6600 точек (рисунок 2.3,а).

На рисунках 2.2 и 2.3 приведены результаты кластеризации описанных моделей данных с помощью алгоритма ССА. Для модели № 1 использовались параметры $m = 15$, $T = 0.3$ (рисунок 2.2,г); для модели № 2 – $m = 15$, $T = 0.3$ (рисунок 2.2,д); для модели № 3 – $m = 25$, $T = 0.2$ (рисунок 2.2,е); для модели № 4 – $m = 20$, $T = 0.7$ (рисунок 2.3,б).

Точность кластеризации для моделей данных № 1-3 составила 100%, а для модели № 4 – 96.35%. Приведенные результаты подтверждают применимость алгоритма к распознаванию линейно неразделимых кластеров, имеющих сложную форму, а также способность разделять кластеры, пересекающиеся в пространстве признаков.

Параметр T определяет порог объединения компонент связности и прямо влияет на итоговое число кластеров. Согласно критерию, при $T = 0$ все смежные компоненты связности будут объединены, а при $T = 1$ будет получено максимальное разделение, соответствующее разбиению на компоненты связности (см пример на рисунке 2.1,г).

Для моделей данных № 1-4 выполнено исследование зависимости результатов кластеризации от параметра T . Значение параметра m фиксировалось, а значение параметра T выбиралось из следующего множества $\{0.1, 0.2, \dots, 0.9, 1\}$. На модели № 1 оптимальное число кластеров было получено при $0.5 \leq T \leq 0.7$; на модели № 2 – при $T = 0.3$; на модели № 3 – при $T \leq 0.2$; на модели № 4 – при $T = 0.7$. В дальнейшем будем задавать параметр T с точностью до 0.1.






Рисунок. 2.2 – Модели данных № 1-3 (а-в) и соответствующие результаты кластеризации алгоритмом CCA (г-е)



а



б

Рисунок 2.3 – Модель данных № 4 (а) и результат кластеризации алгоритмом ССА (б)

Параметр m определяет размер элементов сеточной структуры. На рисунке 2.4 представлены графики зависимости числа кластеров и ошибки кластеризации от значения m , полученные при кластеризации модели данных № 2 (рисунок 2.2,б) при фиксированном значении параметра $T = 0.3$. Графики демонстрируют сильную зависимость результатов кластеризации от параметра m , что затрудняет его настройку. Этим

недостатком обладают все сеточные алгоритмы, использующие одну сетку фиксированного размера [76].




Рисунок 2.4 – Зависимость числа кластеров (а) и ошибки кластеризации (б) от параметра m при кластеризации модели данных № 2 алгоритмом ССА

На рисунке 2.5 представлен результат применения алгоритма ССА к цветному изображению. Размер изображения составляет 2576×1932 пикселей. Каждый пиксель характеризуется тремя компонентами цветовой палитры RGB. При сегментации использовались параметры: $m = 18$, $T = 0.7$. Время обработки составило 0.12 с.



Рисунок 2.5 – Исходное изображение (а); результат сегментации алгоритмом ССА (б)

На рисунке 2.6 представлен результат сегментации мультиспектрального спутникового изображения алгоритмом ССА. Обработывался фрагмент снимка, полученного со спутника Landsat-8, размера 3000×4000 пикселей. При обработке использовались 1-й, 3-й, 5-й и 6-й спектральные каналы. Задавались следующие параметры алгоритма: $m = 18$, $T = 0.9$. Время обработки составило 0.54 с.




Рисунок 2.6 – Фрагмент изображения со спутника Landsat-8 (RGB-композит, каналы 4, 3, 2) (а); результат сегментации алгоритмом ССА (б)

Главным преимуществом применения сеточного подхода является высокое быстроедействие. На рисунке 2.7 представлен график зависимости времени работы алгоритма ССА от числа пикселей N . Использовалось изображение Landsat-8, фрагмент которого представлен на рисунке 2.6,а. Размер изображения варьировался от 1 до 50 миллионов пикселей. При сегментации использовались 1-й, 3-й, 5-й и 6-й спектральные каналы. Задавались следующие параметры алгоритма: $m \in \{18; 32\}$, $T = 0.9$. Полученный график подтверждает линейную зависимость времени работы от числа пикселей изображения N .

Для исследования зависимости времени работы от размерности пространства признаков d использовалось 8-канальное спутниковое изображение размера 2048×2048 пикселей, полученное со спутника WorldView-2 (см рисунок 2.16). При кластеризации использовались первые d каналов изображения, $d \in \{1, \dots, 8\}$. Задавались следующие параметры алгоритма: $m \in \{18; 32\}$, $T = 0.9$. На графике наблюдается экспоненциальная зависимость времени обработки от значения d (рисунок 2.8).




Рисунок 2.7 – Зависимость времени работы алгоритма ССА от числа пикселей N при $m \in \{18; 32\}, T = 0.9$




Рисунок 2.8 – Зависимость времени работы алгоритма ССА от размерности пространства признаков d

Проведенные исследования позволяют заключить, что предложенный алгоритм кластеризации ССА позволяет выделять кластеры сложной структуры и обрабатывать большие массивы данных, что позволяет применять его для обработки мультиспектральных спутниковых снимков. Высокое быстродействие алгоритма позволяет применять его в диалоговом режиме.

В отличие от известных сеточных алгоритмов, ССА позволяет выделять как многомодовые, так и пересекающиеся кластеры. Известные сеточные алгоритмы, в которых кластеры разделяются неплотными клетками (CLIQUE [80], NRI [77], TSING

[78], SLS [79]), не способны разделить пересекающиеся кластеры из-за высокой плотности в области их пересечения [82]. С другой стороны, сеточные алгоритмы, основанные на комбинации плотностного и сеточного подходов (CGDCP [84], ICECPG [85] и GRIDCLUS [86]), для нахождения кластеров используют процедуру восхождения на вершину и не позволяют выделять многомодовые кластеры. Примером использования этого подхода является результат выделения компонент связности (рисунок 2.1,г).

Алгоритм ССА эффективен при обработке мультиспектральных изображений, содержащих до 5 спектральных каналов. При большем числе каналов существенно возрастает время обработки, и проявляется проблема «проклятия размерностей» [24], когда с ростом размерности пространства признаков становится сложнее различать области с высокой и низкой плотностью.

Однако использование фиксированной сетки приводит к тому, что результаты работы алгоритма ССА оказываются неустойчивы к изменению значения параметра m , который определяет размер элементов сеточной структуры. На практике эта неустойчивость затрудняет настройку параметров алгоритма.

2.4. Метод построения ансамбля

Для повышения устойчивости результатов работы алгоритма ССА к изменению значения параметра сетки m предлагается использовать ансамблевый подход. В разделах 2.4-2.5 представлен ансамблевый алгоритм кластеризации ЕССА, в котором используются результаты выполнения алгоритма ССА с разными параметрами сетки. Для формирования итогового коллективного решения применяется метод, основанный на нахождении согласованной матрицы различий объектов [123]. Этот метод может быть описан следующим образом.

Пусть с помощью некоторого алгоритма кластеризации $\mu \in \mu(\theta)$, зависящего от вектора параметров $\theta \in \Theta$ (где Θ – некоторое множество допустимых значений параметров), получен набор частных решений $Q_L = \{Q^{(1)}, \dots, Q^{(l)}, \dots, Q^{(L)}\}$, где $Q^{(l)}$ – l -й вариант разбиения, содержащий $M^{(l)}$ кластеров.

Обозначим через $B(Q^{(l)})$ бинарную матрицу размера $N \times N$, которая для l -й группировки вводится следующим образом:

$$B_{i,j}(Q^{(l)}) = \begin{cases} 0, & \text{если пара объектов отнесена в один кластер;} \\ 1, & \text{иначе.} \end{cases}$$

Определение 2.9. *Согласованная матрица различий $H = \{H_{i,j}\}$, $i, j = 1, \dots, N$ для L частных решений $\{Q^{(1)}, \dots, Q^{(l)}, \dots, Q^{(L)}\}$ вычисляется по формуле*

$$H_{i,j} = \frac{1}{L} \sum_{l=1}^L B_{i,j}(Q^{(l)}).$$

Величина $H_{i,j}$ равна частоте отнесения объектов x_i и x_j в разные кластеры в наборе разбиений Q_L . Близкое к нулю значение $H_{i,j}$ означает, что данные объекты имеют большой шанс попадания в один и тот же кластер. Близкое к единице значение этой величины говорит о том, что шанс оказаться в одном кластере у объектов незначителен.

В работе [123] приведена вероятностная модель ансамблевой решающей функции, построенной с помощью согласованной матрицы различий, и показано, что при выполнении вполне естественных условий, с ростом мощности ансамбля ожидаемая вероятность ошибочной классификации уменьшается, а дисперсия вероятности ошибки стремится к нулю.

Предлагаемый ансамблевый алгоритм ЕССА: $\mu = CCA(m, T)$, где параметр сетки $m \in \{M_{min}, M_{min} + 1, \dots, M_{min} + L - 1\}$, а объектами классификации являются представители компонент связности $\{Y(G_1), \dots, Y(G_S)\}$, позволяет установить соответствия между кластерами из разных разбиений и избежать проблемы быстрогодействия, которая присуща большинству ансамблевых методов [99].

2.5. Ансамблевый сеточный алгоритм кластеризации ЕССА

Предлагаемый алгоритм кластеризации ЕССА(M_{min}, L, T), где M_{min} – параметр масштаба первой сетки, L – число используемых сеток, а T – порог объединения компонент связности, позволяет сформировать ансамблевое решение на основе согласованной матрицы различий для разбиений, построенных сеточным алгоритмом ССА.

Входными данными являются N классифицируемых d -мерных векторов и параметры алгоритма: M_{min}, L, T . Алгоритм ЕССА состоит из четырех основных шагов.

Шаг 1. Выполнение алгоритма ССА(m, T) L раз на наборе параметров $m \in \{M_{min}, M_{min} + 1, \dots, M_{min} + L - 1\}$ при фиксированном значении T .

Шаг 2. Установление соответствия между компонентами связности из разных разбиений. Для всех клеток-представителей компонент связности $\{Y_1^{(L)}, \dots, Y_S^{(L)}\}$, полученных при кластеризации с наибольшим значением параметра m , для каждого разбиения

ния $l = \overline{1, L}$ определяются компоненты связности, в которые попадают эти клетки-представители в пространстве признаков, $G_i^{(l)} = \text{Comp}_l[Y_i^{(L)}]$, $l = \overline{1, L}$; $i = \overline{1, S}$.

Шаг 3. Формирование согласованной матрицы различий. Изначально матрица заполняется нулевыми значениями $\{H[i, j] = 0, i, j = \overline{1, S}\}$. Для каждого разбиения $l = \overline{1, L}$ и для каждой пары представителей компонент связности $Y_i^{(L)}, Y_j^{(L)} \in \{Y_1^{(L)}, \dots, Y_S^{(L)}\}$ в случае, если соответствующие им компоненты связности $G_i^{(l)}, G_j^{(l)}$ при данном разбиении отнесены в разные кластеры, значение $H[i, j]$ увеличивается на 1. После этого матрица нормируется.

Псевдокод шага 3:

$$\text{FOR } (l = \overline{1, L}; i, j = \overline{1, S}) \left\{ \begin{array}{l} \text{IF } (\text{Cluster}^{(l)}[G_i^{(l)}] \neq \text{Cluster}^{(l)}[G_j^{(l)}]) : \\ \quad H[i, j] = H[i, j] + 1; \end{array} \right\}$$

$$H = \frac{H}{L + 1};$$

Шаг 4. Применение агломеративного иерархического алгоритма кластеризации невзвешенной средней связи к полученной согласованной матрице различий H , которая рассматривается как матрица расстояний между представителями компонент связности $\{Y_1^{(L)}, \dots, Y_S^{(L)}\}$. В результате формируется иерархическая структура (дендрограмма), базовыми элементами которой являются компоненты связности $\{G_1^{(L)}, \dots, G_S^{(L)}\}$.

Из полученной иерархической структуры можно получать разбиения данных различной степени подробности, варьируя уровень среза дендрограммы $cut \in [0; 1]$. При этом повторный запуск алгоритма кластеризации не требуется. Кроме того, для автоматической настройки уровня иерархии возможно задание целочисленного значения параметра cut , которое в таком случае определяет требуемое число кластеров.

Для отделения «шума» кластеры, содержащие малое количество элементов (менее заданного параметра τ), относятся к классу «шум».

Оценка вычислительной сложности алгоритма ЕССА.

Вычислительная сложность первого шага ограничена сложностью выполнения алгоритма ССА с наибольшим значением параметра $m = M_{min} + L - 1$ и составляет $\mathcal{O}(N \cdot d + m^d \cdot 3^d)$. Сложность второго этапа ограничена числом обрабатываемых представителей компонент связности S и числом проведенных кластеризаций $\mathcal{O}(L \cdot S)$. Формирование согласованной матрицы различий требует $\mathcal{O}(L \cdot S^2)$ операций.

Сложность построения иерархии на четвертом шаге в среднем составляет $\mathcal{O}(S^2)$. В дальнейшем будем считать, что число элементов ансамбля ограничено ($L < 30$). Таким образом, вычислительная сложность предложенного алгоритма $\text{ECCA}(M_{\min}, L, T)$ при ограниченной размерности данных d составляет $\mathcal{O}(N + (M_{\min})^d + S^2)$. При этом число компонент связности S значительно меньше числа элементов данных N .

На первом шаге ЕССА выполнение алгоритма ССА с различными значениями параметров можно осуществлять независимо, поэтому при реализации использовалось распараллеливание первого и других шагов между ядрами центрального процессора.

2.6. Экспериментальное исследование алгоритма ЕССА

Предложенный алгоритм ЕССА исследовался на модельных и реальных данных.

Для демонстрации устойчивости алгоритма к изменению значения параметра сетки рассматривалась представленная в разделе 2.3 модель данных № 2 (рисунок 2.2,б). На рисунке 2.9 представлен график зависимости точности кластеризации от значения параметра сетки m для алгоритма $\text{CCA}(m, T)$ и для ансамблевого алгоритма $\text{ECCA}(m, L, T)$, использующего 5 и 10 сеток. Значение параметра $T = 0.3$ было зафиксировано. Параметр среза иерархического результата выбирался из условия получения двух кластеров ($\text{cut} = 2$). График показывает устойчивость получаемых результатов к изменению параметра сетки для ансамблевого алгоритма ЕССА, а также рост точности кластеризации с увеличением числа используемых сеток (элементов ансамбля).




Рисунок 2.9 – Зависимость точности кластеризации модели данных № 2 от значения параметра сетки для алгоритмов ССА и ЕССА

Модель данных № 5. Модель состоит из двух двумерных класса, имеющих форму спиралей (рисунок 2.10,а). Каждый класс состоит из 100 точек. Сложность модели заключается в том, что расстояние между точками в каждой спирали увеличивается с отдалением от центра, при этом минимальное расстояние между спиралями сравнительно мало.

Алгоритм ССА позволил получить безошибочный результат кластеризации (рисунок 2.10,б) только при параметрах $m = 31$, $T \in [0.2; 0.3]$. В свою очередь, алгоритм ЕССА точно выделил спирали при следующих значениях параметра сетки: $M_{min} \in \{[37; 44], 46\}$, $L = 5$, $T = 0.3$. А при $L = 15$, $T = 0.3$ ансамблевый алгоритм справился с задачей при еще большем диапазоне значений параметра сетки: $M_{min} \in \{[24; 29], 31, [37; 46]\}$.

На рисунке 2.11 представлены результаты кластеризации, полученные алгоритмом ССА при $m \in [40; 44]$, $T = 0.3$. Ни одно из этих решений не обеспечивает корректного выделения спиралей. Однако построенное на их основе ансамблевое решение позволяет это сделать (рисунок 2.10,б). Использовались соответствующие параметры алгоритма ЕССА: $M_{min} = 40$, $L = 5$, $T = 0.3$. Таким образом, применение ансамблевого подхода не только повышает устойчивость результатов кластеризации, но и позволяет находить новые решения.

Модель данных № 6. На рисунке 2.12,а представлена модель, опубликованная в работе [24] как пример сложных двумерных данных, состоящих из кластеров, различающихся по форме, размеру и плотности, а также содержащих «шум». Используемые для обработки данные были получены путем преобразования изображения из текста статьи в набор из 9388 двумерных точек.

Предложенный алгоритм ЕССА позволил выделить все 7 кластеров, а также исключить «шум» (рисунок 2.12,б). При кластеризации использовались параметры: $M_{min} = 60$, $L = 10$, $T = 0.4$. Срез иерархического результата осуществлялся на уровне $cut = 0.6$. Кластеры, содержащие менее 50 элементов, были отнесены в «шум».




Рисунок 2.10 – Модель данных № 5 (а); результат кластеризации алгоритмом ECCA(40; 5; 0.3) (б)




Рисунок 2.11 – Результаты кластеризации модели данных № 5 алгоритмом CCA(m ; 0.3) при $m \in [40; 44]$




Рисунок 2.12 – модель данных № 6 (а); результат кластеризации алгоритмом ЕССА (б)

Предложенный ансамблевый алгоритм также применялся к данным по ирисам [124], широко используемым при оценке методов классификации с обучением. Эти данные представляют собой результаты четырех типов измерений над 50 цветками от каждой из трех разновидностей ириса, а именно, ириса щетинистого, ириса разноцветного и ириса вирджиника. Измерялись следующие величины: длина и ширина чашелистика, длина и ширина лепестка. Таким образом, данные состоят из 150 точек в четырехмерном пространстве признаков, сгруппированных в 3 класса по 50 элементов (рисунок 2.13). Кластеризация данных производилась алгоритмом ЕССА с параметрами $M_{min} = 25$, $L = 10$, $T = 0.9$ и уровнем среза иерархии $cut = 0.7$. В результате точность кластеризации составила 96%. Обозначим через $|C_i^0|$ число точек, принадлежащих классу i , а через $|C_i^S|$ – число точек, отнесенных в соответствующий кластер. В таблице 2.1 приводятся значения этих параметров для каждого класса.

В работе [51] приведены результаты кластеризации данных по ирисам для двух плотностных непараметрических алгоритмов. Алгоритм k-NN ИТС, использующий оценку плотности на основе k -ближайших соседей, обеспечил точность 96.7%, а для аналогичного алгоритма на основе оценки плотности Розенблатта–Парзена точность составила 92% (указанная точность соответствует определению 2.8). Однако эти алгоритмы характеризуются неприемлемо высокой вычислительной сложностью: $\mathcal{O}(N^2 \cdot \log N)$.




Рисунок 2.13 – Данные по ирисам в трехмерном пространстве признаков

Таблица 2.1 – Результаты кластеризации данных по ирисам алгоритмом ЕССА

	$i = 1$	$i = 2$	$i = 3$
$ C_i^0 $	50	50	50
$ C_i^S $	50	52	48
$ C_i^0 \cap C_i^S $	50	48	46

С точки зрения быстродействия, оптимальное число элементов ансамбля L ратно числу ядер процессора. Поэтому для получения устойчивых результатов и одновременно достижения высокого быстродействия алгоритма ЕССА был выбран наиболее оптимальный набор сеток с параметрами: $m \in \{M_{min}, M_{min} + 2, \dots, M_{min} + 2 \cdot (L - 1)\}$. Для всех последующих экспериментов используется указанный набор из 8 сеток с изменением параметра сетки m с шагом 2, который в дальнейшем будем обозначать $L = 8_{(2)}$.

На рисунке 2.14 представлен результат кластеризации цветного изображения алгоритмом ЕССА. Размер изображения составляет 640×480 пикселей. Каждый пиксель характеризуется тремя компонентами цветовой палитры RGB. Кластеризация осуществлялась с параметрами $M_{min} = 30$, $L = 8_{(2)}$, $T = 0.8$. Время обработки составило 0.04 с. Параметр среза иерархического результата выбирался из условия получения двух кластеров. На рисунке 2.15 показан результат работы алгоритма ЕССА на других уровнях иерархии: $cut \in \{0.1; 0.4; 0.8\}$.

Ансамблевый алгоритм ЕССА на рассматриваемом изображении позволил выделить два неоднородных по цветам кластера: самолет и фон (рисунок 2.14,б) при варьировании значения параметра T от 0.2 до 0.8. В то же время алгоритм ССА при параметре сетки $m = 30$ способен выделить эти два класса только при $T = 0.2$. Таким образом, применение ансамблевого подхода позволяет также упростить настройку параметра T .




Рисунок 2.14 – Исходное изображение (а); результат кластеризации алгоритмом ЕССА (б); алгоритмом К-средних (в); алгоритмом ISODATA (г)




Рисунок 2.15 – Результат кластеризации изображения алгоритмом ЕССА на различных уровнях иерархии $cut \in \{0.1; 0.4; 0.8\}$

Данное изображение (рисунок 2.14,а) также обрабатывалось алгоритмами кластеризации, представленными в программном пакете для обработки спутниковых изображений ENVI 5.0. На рисунке 2.14,в представлен результат кластеризации алгоритмом К-средних с параметром $K = 2$. А на рисунке 2.14,г – результат кластеризации алгоритмом ISODATA с получением 4 кластеров. Для обоих алгоритмов задавалось по 10 вариантов инициализации начальных центров. В результате ни один из этих алгоритмов не позволил отделить представленный на изображении самолет от фона даже при увеличении числа выделяемых кластеров.

На рисунке 2.16 представлен результат применения алгоритма ЕССА к мультиспектральному спутниковому изображению. Обработывался фрагмент снимка, полученного со спутника WorldView-2, размера 2048×2048 пикселей. При кластеризации использовались 1-й, 3-й, 5-й и 8-й спектральные каналы. Задавались следующие параметры алгоритма: $m = 18$, $L = 8_{(2)}$, $T = 0.9$. Срез иерархического результата осуществлялся на уровне $cut = 0.6$. Время обработки составило 0.5 с. Время работы алгоритма ССА на данном изображении при различных параметрах представлено на рисунке 2.8.




Рисунок 2.16 – Изображение со спутника WorldView-2 (RGB-композит, каналы 5, 3, 2) (а); результат кластеризации алгоритмом ЕССА (б)

Многочисленные экспериментальные исследования показали, что предложенный ансамблевый алгоритм кластеризации ЕССА обеспечивает высокое качество получаемых результатов и позволяет выделять многомодовые кластеры сложной структуры

даже в присутствии «шума». Вычислительная эффективность алгоритма позволяет обрабатывать мультиспектральные спутниковые изображения большого размера в диалоговом режиме. В отличие от алгоритма ССА, применение ансамблевого подхода обеспечивает устойчивость результатов кластеризации к изменению значения параметра сетки, что значительно упрощает настройку параметров алгоритма. Кроме того, алгоритм ЕССА позволяет получать иерархическое представление данных, что удобно при интерпретации результатов.

2.7. Краткие выводы по главе

1. Дана формальная постановка задачи кластеризации в рамках сеточного подхода. Создан вычислительно эффективный сеточный алгоритм кластеризации ССА, позволяющий выделять многомодовые кластеры разной формы, размера и плотности.

2. Предложен подход к построению ансамбля сеточных алгоритмов кластеризации на основе согласованной матрицы различий. В рамках этого подхода на основе алгоритма ССА разработан ансамблевый алгоритм кластеризации ЕССА, обеспечивающий устойчивость и качество получаемых результатов.

3. Проведенные экспериментальные исследования на модельных и реальных данных показали, что алгоритмы ССА и ЕССА позволяют выделять кластеры сложной формы, разного размера и плотности. Показано также, что ансамблевый подход позволяет повысить устойчивость получаемых результатов к изменению параметров сетки и значительно облегчить настройку параметров алгоритма. Подтверждена линейная зависимость времени работы разработанных алгоритмов от числа элементов обрабатываемых данных, что обеспечивает возможность сегментации мультиспектральных спутниковых изображений в диалоговом режиме.

Глава 3. Иерархические алгоритмы кластеризации мультиспектральных изображений на основе сеточного и ансамблевого подходов

Иерархическое представление удобно при интерпретации результатов кластеризации. Однако, как показано в разделе 1.2.2, существующие иерархические алгоритмы не позволяют разделять пересекающиеся кластеры и имеют высокую вычислительную трудоемкость, поэтому они не применимы для обработки спутниковых изображений. В работе [41] было показано, что введение в признаковом пространстве метрики, учитывающей плотность распределения данных, позволяет избежать проблемы с разделением пересекающихся кластеров. Однако предложенный в этой работе подход также характеризуется высокой вычислительной сложности ($\mathcal{O}(N^2)$).

В данной главе предлагаются вычислительно эффективные иерархические алгоритмы кластеризации НСА и НЕСА для сегментации мультиспектральных спутниковых изображений, разработанные в рамках сеточного и ансамблевого подходов. Для построения иерархии вводится специальная метрика между элементами сеточной структуры, основанная на непараметрической оценке плотности распределения данных.

3.1. Ультраметрика для построения иерархии данных в рамках сеточной структуры

Для построения метрики в рамках сеточного подхода будем использовать введенные в главе 2 определения 2.1 (*сеточная структура*), 2.4 (*компоненты связности*) и 2.5 (*представители компонент связности*).

Определение 3.1. Расстояние h_{ij} между парой смежных компонент связности G_i и G_j ($i, j = \overline{1, S}$) определим по формуле

$$h_{ij} = \min_{P_{ij} \in \mathfrak{R}_{ij}} \left[1 - \min_{B_{k_t} \in P_{ij}} D_{B_{k_t}} / \min(D_{Y(G_i)}, D_{Y(G_j)}) \right],$$

где $\mathfrak{R}_{ij} = \{P_{ij}\}$ – множество всех цепочек, связывающих представителей компонент связности $P_{ij} = \langle Y(G_i) = B_{k_1}, \dots, B_{k_t}, B_{k_{t+1}}, \dots, B_{k_l} = Y(G_j) \rangle$ таких, что для всех $t = 1, \dots, l-1$ 1) $B_{k_t} \in G_i \cup G_j$; 2) $B_{k_t}, B_{k_{t+1}}$ – смежные клетки. В случае если компоненты связности G_i и G_j не являются смежными, положим $h_{ij} = 1$.

Определение 3.2. Построим *матрицу расстояний между компонентами связности* $\{\tilde{h}_{ij}\}$ на основе матрицы расстояний между смежными компонентами связности $\{h_{ij}\}$ следующим образом. Пусть $\Theta_{ij} = \{Q_{ij}\}$ – множество всех цепочек, элементами которых являются компоненты связности, $Q_{ij} = \langle G_i = G_{k_1}, \dots, G_{k_t}, G_{k_{t+1}}, \dots, G_{k_l} = G_j \rangle$ таких, что для всех $t = 1, \dots, l-1$ компоненты $G_{k_t}, G_{k_{t+1}}$ смежные. Тогда расстояние между произвольными компонентами связности G_i и G_j вычисляется по формуле

$$\tilde{h}_{ij} = \min_{Q_{ij} \in \Theta_{ij}} [\max_t h_{k_t, k_{t+1}}].$$

В случае если множество Θ_{ij} пусто, то полагаем $\tilde{h}_{ij} = 1$. Для всех компонент связности $i = 1, \dots, S$ определим $\tilde{h}_{ii} = 0$.

Для фиксированной цепочки $Q_{ij} = \langle G_i = G_{k_1}, \dots, G_{k_t}, G_{k_{t+1}}, \dots, G_{k_l} = G_j \rangle$ определим ее длину следующим образом: $d(Q_{ij}) = \max_t h_{k_t, k_{t+1}}$. Тогда расстояние между компонентами связности G_i и G_j можно переписать в виде

$$\tilde{h}_{ij} = \min_{Q_{ij} \in \Theta_{ij}} [d(Q_{ij})].$$

Определение 3.3. *Ультраметрикой* [125] называется функция $d: M \times M \rightarrow \mathbb{R}$, удовлетворяющая следующим условиям.

Для любых элементов $x, y, z \in M$ выполняются условия:

- 1) $d(x, y) \geq 0$; $d(x, y) = 0 \Leftrightarrow x = y$;
- 2) $d(x, y) = d(y, x)$;
- 3) $d(x, z) \leq \max(d(x, y), d(y, z))$.

Утверждение 3.1. Введенное расстояние $\tilde{h}_{ij}$ обладает свойством ультраметрики на множестве компонент связности.

Доказательство. Выполнение условий положительной определенности и симметричности очевидны и следуют из определения $\tilde{h}_{ij}$. Необходимо показать, что выполняется усиленное неравенство треугольника: $\tilde{h}_{ij} \leq \max(\tilde{h}_{ik}, \tilde{h}_{kj})$, $\forall i, j, k$.

Обозначим через $\Theta_{ikj} = \{Q_{ikj}\}$ – множество всех простых цепей с концами G_i и G_j , проходящих через G_k : $Q_{ikj} = \langle G_i, \dots, G_k, \dots, G_j \rangle$. Очевидно, что $\Theta_{ikj} \subseteq \Theta_{ij}$. Поэтому

$$\begin{aligned} \tilde{h}_{ij} &= \min_{Q_{ij} \in \Theta_{ij}} [d(Q_{ij})] \leq \min_{Q_{ikj} \in \Theta_{ikj}} [d(Q_{ikj})] = \\ &= \min_{Q_{ik} \in \Theta_{ik}} \min_{Q_{kj} \in \Theta_{kj}} [\max(d(Q_{ik}), d(Q_{kj}))] = \\ &= \max(\min_{Q_{ik} \in \Theta_{ik}} [d(Q_{ik})], \min_{Q_{kj} \in \Theta_{kj}} [d(Q_{kj})]) = \max(\tilde{h}_{ik}, \tilde{h}_{kj}). \quad \blacksquare \end{aligned}$$

Ультраметрика обладает следующим важным свойством: всякий треугольник является равнобедренным, причем если не все его стороны равны, то одна – короче, чем две других. Это означает, что при применении агломеративного иерархического алгоритма кластеризации к матрице расстояний, для которой выполняется свойство ультраметрики, на всех уровнях иерархии расстояние между кластерами не зависит от способа определения расстояния между двумя множествами (методом ближайшего соседа, дальнего соседа или средней связи). Следовательно, по такой матрице может быть построен только один вариант дендрограммы.

Известно [126], что существует однозначное соответствие между матрицами расстояний со свойством ультраметрики и дендрограммами, поэтому такие матрицы можно использовать в качестве дескрипторов для описания иерархических результатов.

3.2. Вычисление ультраметрики с помощью метода ближайшего соседа

Процедура получения ультраметрики $\{\tilde{h}_{ij}\}$ из матрицы расстояний смежных объектов $\{h_{ij}\}$ в литературе известна как операция минимального транзитивного замыкания (minimum transitive closure) [126-128]. Для ее реализации, как правило, применяются вычислительно трудоемкие алгоритмы. Например, в работе [126] используется метод умножения матриц, вычислительная сложность которого составляет $O(n^4)$ (для матрицы расстояний размера $n \times n$). В [127] применяется модификация алгоритма Флойда – Уоршелла с вычислительной сложностью $O(n^3)$. В [128] предлагается использовать рекурсивный проход всех цепочек поиском в глубину (или ширину), начиная с каждого элемента. Сложность этого подхода в среднем составляет $O(n^2)$, но в худшем случае может достигать $O(n^3)$.

Следующее утверждение показывает, что операцию минимального транзитивного замыкания можно выполнить с помощью агломеративного алгоритма построения дендрограммы методом ближайшего соседа, который можно реализовать с вычислительной сложностью $O(n^2)$ [129].

Утверждение 3.2. Дендрограмма, соответствующая ультраметрике $\{\tilde{h}_{ij}\}$, совпадает с дендрограммой, полученной с помощью применения метода ближайшего соседа к матрице расстояний $\{h_{ij}\}$.

Доказательство. Выберем произвольное значение среза дендрограммы $\alpha \in [0; 1]$. Пусть R_α и $\tilde{R}_\alpha$ – отношения эквивалентности (принадлежности к одному кластеру), полученные в результате среза дендрограмм, построенных по матрицам $\{h_{ij}\}$ и $\{\tilde{h}_{ij}\}$ соответственно, на уровне среза α .

Покажем, что отношения эквивалентности $\tilde{R}_\alpha$ и R_α совпадают для каждого уровня среза дендрограммы α .

В соответствии с методом одиночной связи, элементы i и j принадлежат к одному кластеру тогда и только тогда, когда существует цепочка $Q_{ij} \in \Theta_{ij}$, в которой длины всех отрезков не превышают α , т.е. $d(Q_{ij}) \leq \alpha$.

Возможны два случая.

1. Пусть элементы i и j принадлежат к одному кластеру по отношению R_α . $iR_\alpha j \Leftrightarrow \exists Q_{ij} \in \Theta_{ij}: d(Q_{ij}) \leq \alpha \Rightarrow \tilde{h}_{ij} \leq \alpha \Rightarrow i\tilde{R}_\alpha j$. Таким образом, i и j принадлежат к одному кластеру по отношению $\tilde{R}_\alpha$.

2. Пусть элементы i и j принадлежат разным кластерам по отношению R_α . $\neg(iR_\alpha j) \Leftrightarrow \forall Q_{ij} \in \Theta_{ij}: d(Q_{ij}) > \alpha \Rightarrow \min_{Q_{ij} \in \Theta_{ij}} [d(Q_{ij})] > \alpha \Rightarrow \tilde{h}_{ij} > \alpha$. По свойству о равнобедренности треугольников $\forall Q_{ij} \in \Theta_{ij}$, $Q_{ij} = \langle G_i = G_{k_1}, \dots, G_{k_t}, G_{k_{t+1}}, \dots, G_{k_l} = G_j \rangle$: $\max_t \tilde{h}_{k_t, k_{t+1}} \geq \tilde{h}_{ij} > \alpha \Rightarrow \neg(i\tilde{R}_\alpha j)$. Таким образом, элементы i и j принадлежат различным кластерам по отношению $\tilde{R}_\alpha$.

Следовательно, отношения $\tilde{R}_\alpha$ и R_α совпадают для каждого значения α , соответственно, построенные дендрограммы полностью совпадают. ■

3.3. Иерархический сеточный алгоритм кластеризации НСА

Предлагаемый алгоритм НСА(m), где m – параметр масштаба сетки, позволяет выполнять иерархическую кластеризацию в рамках сеточного подхода на основе предложенной ультраметрики.

Входными данными являются N классифицируемых d -мерных векторов и параметр m . Алгоритм НСА состоит из пяти шагов, выполняемых последовательно. При этом первые 3 шага, необходимые для выделения компонент связности, совпадают с соответствующими шагами алгоритма ССА.

Шаг 1. Формирование многомерной гистограммы. Создается массив, элементами которого являются плотности клеток. Изначально массив инициализируется нулевыми значениями $\{D_{B_i} = 0, i = \overline{1, m^d}\}$. Для каждого вектора данных вычисляется и запоминается номер клетки, в которую он попадает $\{Cell[x_i], i = \overline{1, N}\}$. При этом плотность соответствующей клетки увеличивается на единицу.

Псевдокод шага 1:

FOR ($i = \overline{1, N}$): $D_{Cell[x_i]} = D_{Cell[x_i]} + 1$;

Шаг 2. Формирование массива ссылок для непосредственно связанных клеток $\{Link[B_i], i = \overline{1, m^d}\}$. Для каждой непустой клетки среди смежных с ней клеток и ее самой выбирается максимальная по номеру клетки с наибольшей плотностью. В формируемый массив заносится ссылка на выбранную клетку. На данном этапе также определяются представители компонент связности $\{Y(G_1), \dots, Y(G_s)\}$, как клетки со ссылками на самих себя.

Псевдокод шага 2:

$\{Y(G_i)\} = \emptyset$;

FOR ($i: D_{B_i} > 0$) $\left\{ \begin{array}{l} Link[B_i] = \max_k \arg \max_{B_k \in (B_i \cup A_{B_i})} D_{B_k}; \\ IF (Link[B_i] = B_i): B_i \rightarrow \{Y(G_i)\}; \end{array} \right\}$

Шаг 3. Выделение компонент связности. Создается массив, элементами которого являются компоненты связности для каждой клетки. Изначально массив инициализируется нулевыми значениями $\{Comp[B_i] = 0, i = \overline{1, m^d}\}$. Для каждой непустой нерассмотренной клетки осуществляется последовательный переход по ссылкам к непосредственно связным клеткам вплоть до достижения клетки-представителя компоненты связности или уже рассмотренной клетки. Затем пройденная цепочка клеток относится к соответствующей компоненте связности.

Псевдокод шага 3:

FOR ($i = \overline{1, s}$): $Comp[Y(G_i)] = G_i$;

FOR ($i: D_{B_i} > 0, Comp[B_i] = 0$) $\left\{ \begin{array}{l} B = B_i; \{Q\} = \{B\}; \\ WHILE (Comp[B] = 0): \{B = Link[B_i]; B \rightarrow \{Q\}\}; \\ FOR (B_j \in Q): Comp[B_j] = Comp[B]; \end{array} \right\}$

Шаг 4. Формирование матрицы расстояний между смежными компонентами связности. Изначально матрица заполняется единицами, а диагональ – нулевыми значениями $\{H[i, j] = 1, i \neq j, i, j = \overline{1, S}; H[i, i] = 0, i = \overline{1, S}\}$. Среди всех пар непустых смежных клеток рассматриваются только те, которые принадлежат к разным компонентам связности (граничные). Для рассматриваемой пары клеток $B_i \in G_k, B_j \in G_l (G_k \neq G_l)$ и клеток-представителей соответствующих компонент связности $Y(G_k), Y(G_l)$ вычисляется расстояние: $d_{ij} = 1 - \min(D_{B_i}, D_{B_j}) / \min(D_{Y(G_k)}, D_{Y(G_l)})$. Если расстояние d_{ij} оказывается меньше текущего значения $H[k, l]$, то расстояние между компонентами связности G_k и G_l пересчитывается: $H[k, l] = d_{ij}$.

Псевдокод шага 4:

$$FOR \left(\begin{array}{l} i, j: D_{B_i} > 0, D_{B_j} > 0, \\ B_j \in A_{B_i}, Comp[B_i] \neq Comp[B_j] \end{array} \right) \left\{ \begin{array}{l} G_k = Comp[B_i]; G_l = Comp[B_j]; \\ d_{ij} = 1 - \frac{\min(D_{B_i}, D_{B_j})}{\min(D_{Y(G_k)}, D_{Y(G_l)})}; \\ IF (d_{ij} < H[k, l]): \\ H[k, l] = d_{ij}; \end{array} \right\}$$

Шаг 5. Применение агломеративного иерархического алгоритма кластеризации ближайшего соседа (SLINK) к полученной матрице расстояний $H[i, j]$. В результате формируется иерархическая структура (дендрограмма), базовыми элементами которой являются компоненты связности $\{G_1, \dots, G_S\}$.

Из полученной иерархической структуры можно получать разбиения данных различной степени подробности, варьируя значение уровня среза дендрограммы $cut \in [0; 1]$. При этом повторный запуск алгоритма НСА не требуется. Кроме того, для настройки искомого уровня иерархии возможно прямое задание числа кластеров.

Вычислительная сложность первых четырех шагов определяется сложностью выполнения алгоритма ССА и составляет $O(N \cdot d + m^d \cdot 3^d)$. Сложность построения иерархии на пятом шаге составляет $O(S^2)$. Таким образом, вычислительная сложность предложенного алгоритма НСА(m) при ограниченной размерности данных d составляет $O(N + m^d + S^2)$. При этом число компонент связности S значительно меньше числа элементов данных N . На практике время работы алгоритма НСА практически не отличается от времени работы алгоритма ССА и имеет аналогичную зависимость от значений N, d и параметра сетки m .

3.4. Экспериментальное исследование алгоритма НСА

Предложенный алгоритм НСА исследовался на модельных и реальных данных.

Для сравнения качества работы алгоритма НСА с другими алгоритмами использовался открытый программный пакет ELKI [130], включающий в себя такие известные алгоритмы кластеризации, как К-средних, EM, DBSCAN, OPTICS, DeLiClu, а также стандартные алгоритмы построения иерархических разбиений методами ближайшего соседа, дальнего соседа и средней связи.

Модель данных № 7. Модельные данные состоят из восьми равновероятных классов в двумерном пространстве признаков. Первые пять классов описываются нормальным распределением с векторами математического ожидания $\mu_1 = (40, 55)$, $\mu_2 = (40, 125)$, $\mu_3 = (40, 195)$, $\mu_4 = (150, 210)$, $\mu_5 = (215, 180)$ и одинаковой для всех ковариационной матрицей $\Sigma = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix}$, где $\sigma = 14$. Другие три класса также имеют нормальное распределение с векторами математического ожидания $\mu_6 = (160, 55)$, $\mu_7 = (185, 25)$, $\mu_8 = (210, 55)$ и ковариационной матрицей $\Sigma = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix}$, где $\sigma = 10$. Последняя группа состоит из тесно расположенных кластеров, которые значительно пересекаются в пространстве признаков. Для каждого из восьми классов генерировалось по 500 точек (рисунок 3.1,а).

На рисунке 3.1,б-г представлен результат кластеризации этой модели, полученный с помощью предложенного алгоритма НСА при $m = 32$. Представлены срезы иерархического результата на уровнях: 0.5 (рисунок 3.1,б); 0.8 (рисунок 3.1,в); 0.97 (рисунок 3.1,г). Кластеры, содержащие менее 50 элементов, были отнесены в «шум». Алгоритм НСА позволил выделить все восемь классов (рисунок 3.1,б) с точностью 97.98%, а также позволил выявить иерархическую структуру данных (рисунок 3.1,б-г).

Алгоритмы кластеризации К-средних и EM, предназначенные для разделения нормально распределенных классов, способны выделить все 8 классов только при удачной инициализации центров. В то же время плотностные алгоритмы (DBSCAN, OPTICS и DeLiClu), а также стандартные иерархические методы (ближайшего соседа, дальнего соседа, взвешенной средней связи) не способны разделить пересекающуюся группу из трех кластеров. В результате их применения выделяется не более шести кластеров (в зависимости от значений выбранных параметров).




Рисунок 3.1 – Модель данных № 7 (а); результат кластеризации алгоритмом НСА на различных уровнях иерархии (б-г)

Модель данных № 8. Модельные данные состоят из пяти равновероятных классов в двумерном пространстве признаков. Три класса описываются нормальным распределением с векторами математического ожидания $\mu_1 = (188, 100)$, $\mu_2 = (75, 100)$, $\mu_3 = (75, 150)$ и ковариационными матрицами $\Sigma_1 = \begin{pmatrix} 4^2 & 0 \\ 0 & 4^2 \end{pmatrix}$, $\Sigma_2 = \begin{pmatrix} 12^2 & 0 \\ 0 & 12^2 \end{pmatrix}$, $\Sigma_3 = \begin{pmatrix} 21^2 & 0 \\ 0 & 8^2 \end{pmatrix}$ соответственно. Элементы четвертого класса равномерно распределены по кольцу с центром в точке $(188, 100)$ и радиусами $R_{min} = 20$, $R_{max} = 25$. Элементы пятого класса распределены равномерно по окружности с центром в точке $(188, 100)$ и радиусом $R = 45$ и дополнительно смещены по радиусу на случайную величину, характеризующуюся нормальным распределением со среднеквадратичным отклонением

$\sigma = 4$. Для пяти классов генерировалось 220, 600, 600, 400, 500 точек соответственно (рисунок 3.2,а).

На рисунке 3.2,б представлен результат кластеризации данной модели алгоритмом НСА при $m = 38$. Параметр среза иерархического результата выбирался из условия получения пяти кластеров. В результате точность кластеризации (определяемая в соответствии с определением 2.8) составила 99.44%.

Ни один алгоритм из пакета ELKI не смог правильно выделить все пять кластеров. Наилучшие результаты показал плотностной иерархический алгоритм OPTICS, достигнув точности 79.7% (рисунок 3.2,в) при значениях параметров $\epsilon = 12$, $minpts = 8$ и уровне среза иерархии 4.9, а также иерархический алгоритм ближайшего соседа (SLINK) с точностью 72.72% (рисунок 3.2,г) при значении параметра $threshold = 5$.




Рисунок 3.2 – Модель данных № 8 (а); результат кластеризации алгоритмом НСА (б); алгоритмом OPTICS (в); алгоритмом SLINK (г)

На рисунке 3.3 представлен результат сегментации мультиспектрального спутникового изображения алгоритмом НСА. Обработывался фрагмент снимка, полученного со спутника WorldView-2, размера 2048×2048 пикселей (рисунок 3.3,а). При сегментации использовались 1-й, 2-й, 4-й и 7й каналы. Параметр сетки m задавался равным 27. Представлены срезы иерархического результата на уровнях: 0.23 (рисунок 3.3,б); 0.2 (рисунок 3.3,в); 0.0 (рисунок 3.3,г). Время обработки составило 0.28 с.




Рисунок 3.3 – Изображение со спутника WorldView-2 (RGB-композит, каналы 5, 3, 2) (а); результат кластеризации алгоритмом НСА на различных уровнях иерархии (б-г)

На рисунке 3.4 представлен график зависимости точности кластеризации от значения параметра m , полученный на модели данных № 2 алгоритмом НСА

(рисунок 2.2,б). Параметр среза иерархического результата выбирался из условия получения двух кластеров. График демонстрирует сильную зависимость результатов кластеризации от значения параметра сетки m .




Рисунок 3.4 – Зависимость точности кластеризации модели данных № 2 от значения параметра сетки m для алгоритма НСА

Предложенный алгоритм кластеризации НСА позволяет выделять кластеры сложной структуры и получать иерархическое представление данных. Экспериментальные исследования показали, что, в отличие от распространенных иерархических алгоритмов кластеризации, НСА способен эффективно разделять пересекающиеся в пространстве признаков кластеры. Вычислительная эффективность алгоритма позволяет обрабатывать мультиспектральные спутниковые изображения в диалоговом режиме.

Недостатком алгоритма является использование фиксированной сетки, вследствие чего результаты его работы значительно зависят от изменения параметра m , который определяет размер элементов сеточной структуры. На практике эта неустойчивость затрудняет настройку параметра алгоритма.

3.5. Построение ансамбля иерархических разбиений

Повысить качество и устойчивость результатов иерархической кластеризации, как показано в работах [39, 126, 127, 131], можно с помощью ансамблевого подхода. Однако известные алгоритмы формирования ансамбля иерархических разбиений

являются вычислительно трудоемкими и не применимы для обработки спутниковых изображений.

В данном разделе представлен способ построения ансамбля иерархических разбиений, который предлагается использовать для повышения устойчивости результатов кластеризации алгоритма НСА к изменению значения параметра сетки.

Пусть для анализируемых данных имеется некоторый набор иерархических разбиений $\{D^{(1)}, \dots, D^{(l)}, \dots, D^{(L)}\}$. Сочетание иерархий, представленных в виде дендрограмм, является затруднительным из-за возможных отличий в топологии деревьев. Поэтому удобнее использовать матричное представление [39, 126, 127]. Для каждой дендрограммы $D^{(l)}$ существует соответствующая матрица расстояний $M^{(l)}$, обладающая свойством ультраметрики. При этом элемент $M_{ij}^{(l)}$ матрицы $M^{(l)}$ равен наименьшей высоте дерева, при которой объединяется пара элементов i, j .

Таким образом, задачу сочетания иерархических разбиений можно сформулировать как задачу поиска «средней ультраметрики» $M^* \in U$ (где U – множество всех матриц размера $N \times N$ со свойством ультраметрики), которая максимально близка одновременно ко всем исходным ультраметрикам $\{M^{(1)}, \dots, M^{(l)}, \dots, M^{(L)}\}$:

$$M^* = \arg \min_{M \in U} \sum_{l=1}^L \|M^{(l)} - M\|^2.$$

Однако поиск «средней ультраметрики» M^* является NP-трудной оптимизационной задачей [132] и неприменим на практике.

Определение 3.4. *Согласованная матрица расстояний $R = \{R_{ij}\}$, $i, j = 1, \dots, N$ для матриц расстояний $\{M^{(1)}, \dots, M^{(l)}, \dots, M^{(L)}\}$ определяется по формуле*

$$R_{ij} = \frac{1}{L} \sum_{l=1}^L M_{ij}^{(l)}.$$

Задачу поиска «средней ультраметрики» можно переформулировать в задачу нахождения ультраметрики, ближайшей к согласованной матрице расстояний [132]:

$$M^* = \arg \min_{M \in U} \|R - M\|^2.$$

Таким образом, согласованная матрица расстояний R является хорошим приближением M^* . Для получения ультраметрики из матрицы R к ней можно применить один из стандартных агломеративных методов построения дендрограммы [39, 127].

В работе [132] отмечается, что применение метода средней связи (UPGMA) к согласованной матрице расстояний очень часто дает результат, совпадающий с результатами трудоемких оптимизационных методов по поиску M^* . Полученная таким образом дендрограмма может рассматриваться как результат сочетания иерархических разбиений.

В разделе 3.6 предлагается ансамблевый иерархический алгоритм кластеризации НЕСА, в котором используются результаты выполнения алгоритма НСА с разными параметрами сетки. Для формирования коллективного решения применяется метод, основанный на нахождении согласованной матрицы расстояний с последующим построением дендрограммы методом невзвешенной средней связи. При этом в качестве элементов иерархии выступают компоненты связности, построенные алгоритмом ССА.

3.6. Иерархический сеточный алгоритм кластеризации НЕСА на основе ансамблевого подхода

Предлагаемый алгоритм $\text{НЕСА}(M_{\min}, L)$, где $M_{\min}$ – параметр масштаба первой (самой крупной) сетки, L – число используемых сеток, позволяет формировать ансамблевое решение на основе согласованной матрицы расстояний для иерархических результатов кластеризации, полученных с помощью сеточного алгоритма НСА.

Входными данными алгоритма являются N классифицируемых d -мерных векторов, а также параметры $M_{\min}$ и L . Алгоритм НЕСА состоит из четырех основных шагов.

Шаг 1. Выполнение алгоритма $\text{НСА}(m)$ L раз с набором параметров $m \in \{M_{\min}, M_{\min} + 2, \dots, M_{\min} + 2 \cdot (L - 1)\}$. Для каждого полученного иерархического результата (дендрограммы) вычисляются соответствующие матрицы расстояний между компонентами связности $\{H^{(l)}[i, j], i, j = \overline{1, S^{(l)}}\}$, $l = \overline{1, L}$, обладающие свойством ультраметрики.

Шаг 2. Установление соответствия между компонентами связности из разных разбиений. Для всех клеток-представителей компонент связности $\{Y_1^{(L)}, \dots, Y_S^{(L)}\}$, полученных при кластеризации с наибольшим значением параметра m , в каждом из разбиений $l = \overline{1, L}$ определяются содержащие их компоненты связности: $\{G_i^{(l)} = \text{Comp}_l[Y_i^{(L)}], l = \overline{1, L}, i = \overline{1, S}\}$.

Шаг 3. Формирование согласованной матрицы расстояний. Изначально матрица заполняется нулевыми значениями $\{R[i, j] = 0, i, j = \overline{1, S}\}$. Для каждого

разбиения $l = \overline{1, L}$ и для каждой пары представителей компонент связности $Y_i^{(l)}, Y_j^{(l)} \in \{Y_1^{(l)}, \dots, Y_S^{(l)}\}$ к значению $R[i, j]$ прибавляется расстояние между соответствующими компонентами связности $H^{(l)}[G_i^{(l)}, G_j^{(l)}]$. После этого матрица нормируется.

Псевдокод шага 3:

FOR ($l = \overline{1, L}; i, j = \overline{1, S}$): $R[i, j] = R[i, j] + H^{(l)}[G_i^{(l)}, G_j^{(l)}]$;

$$R = \frac{R}{\max_{i, j = \overline{1, S}} (R[i, j])};$$

Шаг 4. Применение агломеративного иерархического алгоритма кластеризации невзвешенной средней связи (UPGMA) к полученной согласованной матрице расстояний R . В результате формируется иерархическая структура (дендрограмма), базовыми элементами которой являются компоненты связности $\{G_1^{(L)}, \dots, G_S^{(L)}\}$.

Предложенный алгоритм позволяет за один запуск получать разбиения данных различной степени подробности посредством варьирования значения уровня среза дендрограммы $cut \in [0; 1]$ или задания желаемого числа кластеров.

Проведенные экспериментальные исследования показали преимущество использования метода средней связи на четвертом шаге алгоритма по сравнению с другими методами построения иерархии. Он позволяет выделять составные объекты, состоящие из нескольких различных компонент.

На рисунке 3.5 представлен результат применения алгоритма HECA к цветному изображению (рисунок 3.5,а). При сегментации использовались параметры $M_{min} = 18$, $L = 8$. Алгоритм позволил выделить на изображении автомобиль (рисунок 3.5,г). Однако при использовании на последнем шаге алгоритма HECA метода ближайшего соседа (SLINK), выделить автомобиль (как единое целое) не удастся ни на одном из уровней иерархии (рисунок 3.5,в).

Описанный эффект проявляется и при кластеризации модельных данных. На рисунке 3.6 представлен график зависимости точности кластеризации модели данных № 2 (рисунок 2.2,б) от значения параметра M_{min} при $L = 8$ при использовании на последнем шаге метода средней связи (UPGMA) и метода ближайшего соседа (SLINK). Параметр среза иерархического результата выбирался из условия получения двух кластеров.




Рисунок 3.5 – Исходное изображение (а); результат сегментации алгоритмом HECA на нулевом уровне иерархии (б); результат при использовании метода SLINK (в) и UPGMA (г) на последнем шаге




Рисунок 3.6 – Зависимость точности кластеризации модели данных № 2 алгоритмом HECA от значения параметра M_{min} при использовании на последнем этапе методов SLINK и UPGMA

Оценка вычислительной сложности алгоритма НЕСА.

Вычислительная сложность первого шага определяется сложностью выполнения алгоритма НСА с наибольшим значением параметра сетки $m = M_{min} + 2 \cdot (L - 1)$ и составляет $\mathcal{O}(N \cdot d + m^d \cdot 3^d + S^2)$. Сложность второго этапа ограничена числом обрабатываемых представителей компонент связности S и числом проведенных кластеризаций $\mathcal{O}(L \cdot S)$. Формирование согласованной матрицы расстояний требует $\mathcal{O}(L \cdot S^2)$ операций. Сложность построения иерархии на четвертом шаге в среднем составляет $\mathcal{O}(S^2)$. Таким образом, вычислительная сложность предложенного алгоритма $\text{HECA}(M_{min}, L)$ при ограниченной размерности данных d составляет $\mathcal{O}(N + (M_{min})^d + S^2)$. При этом число компонент связности S значительно меньше числа элементов данных N .

На первом шаге НЕСА выполнение алгоритма НСА с разными наборами параметров можно осуществлять независимо, поэтому при программной реализации алгоритма НЕСА использовалось распараллеливание между ядрами центрального процессора.

3.7. Экспериментальное исследование алгоритма НЕСА

Предложенный алгоритм НЕСА исследовался на модельных и реальных данных.

Для демонстрации устойчивости алгоритма к изменению значения параметра сетки использовалась модель данных № 2. На рисунке 3.7 представлен график зависимости точности кластеризации от значения параметра сетки m для алгоритма $\text{НСА}(m)$ и для ансамблевого алгоритма $\text{HECA}(m, L)$ с использованием 2, 4 и 8 сеток. Параметр среза иерархического результата выбирался из условия получения двух кластеров.




Рисунок 3.7 – Зависимость точности кластеризации модели данных № 2 от значения параметра сетки для алгоритмов НСА и НЕСА

Представленный график показывает устойчивость получаемых результатов к изменению параметра сетки для алгоритма НЕСА, а также увеличение точности кластеризации с ростом числа используемых сеток (элементов ансамбля).

Многочисленные экспериментальные исследования показывали, что использование 8 элементов ансамбля достаточно для получения устойчивых результатов.

Модель данных № 9 [133]. Модельные данные состоят из восьми равновероятных классов в двумерном пространстве признаков. Четыре класса описываются нормальным распределением с векторами математического ожидания $\mu_1 = (192, 192)$, $\mu_2 = (64, 70)$, $\mu_3 = (64, 192)$, $\mu_4 = (64, 140)$ и ковариационными матрицами $\Sigma_1 = \begin{pmatrix} 4^2 & 0 \\ 0 & 4^2 \end{pmatrix}$, $\Sigma_2 = \begin{pmatrix} 18^2 & 0 \\ 0 & 18^2 \end{pmatrix}$, $\Sigma_3 = \begin{pmatrix} 20^2 & 0 \\ 0 & 8^2 \end{pmatrix}$, $\Sigma_4 = \begin{pmatrix} 5^2 & 0 \\ 0 & 11^2 \end{pmatrix}$ соответственно. Элементы пятого класса равномерно распределены по кольцу с центром в точке $(192, 192)$ и радиусами $R_{min} = 20$, $R_{max} = 25$. Элементы шестого класса распределены равномерно по окружности с центром в точке $(192, 192)$ и радиусом $R = 45$ и дополнительно смещены по радиусу на случайную величину, характеризующуюся нормальным распределением со среднеквадратичным отклонением $\sigma = 4$. Седьмой и восьмой классы представляют собой спирали, исходящие из точки $(192, 64)$ в разные стороны. Для классов генерировалось 220, 500, 500, 200, 400, 500, 76, 76 точек соответственно (рисунок 3.8,а).

На рисунке 3.8,б представлен результат кластеризации модели алгоритмом НЕСА при $M_{min} = 38$, $L = 8$. Срез иерархического результата выбирался так, чтобы получить восемь кластеров. В результате точность кластеризации (определенная в соответствии с определением 2.8) составила 99.31%.

Ни один алгоритм кластеризации из пакета ELKI не смог правильно выделить все кластеры. Наилучшие результаты показал плотностной иерархический алгоритм DeLiClu (94.66%) при значении параметра $minpts = 2$ и уровне среза иерархии 5.0, однако он не способен выделить кластеры спиралевидной формы (рисунок 3.8,в). Иерархический алгоритм ближайшего соседа (SLINK) позволил выделить спиралевидные кластеры при значении параметра $threshold = 7$ и достичь точности кластеризации 90.29%, однако он не смог разделить два близлежащих кластера, характеризующихся нормальным распределением (рисунок 3.8,г).




Рисунок 3.8 – Модель данных № 9 (а); результат кластеризации алгоритмами HECA (б), DeLiClu (в) и SLINK (г)

На рисунке 3.9,б представлен результат сегментации цветного изображения (рисунок 3.9,а) алгоритмом HECA. Размер изображения составляет 600×396 пикселей. Каждый пиксель характеризуется тремя компонентами цветовой палитры RGB. При сегментации использовались параметры $M_{min} = 18$, $L = 8$. Срез иерархического результата осуществлялся на уровне $cut = 0.8$. Время обработки составило 0.03 с.

Данное изображение было также обработано алгоритмами кластеризации, представленными в программном пакете для обработки спутниковых изображений ENVI 5.0. На рисунке 3.9,в представлен результат сегментации изображения алгоритмом К-средних с параметром $K = 5$. А на рисунке 3.9,г – результат применения алгоритма ISODATA с выделением 8 кластеров. Для обоих алгоритмов задавалось по 10 вариантов

инициализации начальных центров. Ни один из этих алгоритмов не позволил отделить представленного на изображении снежного барса от снежной поверхности даже при увеличении числа кластеров.




Рисунок 3.9 – Исходное изображение (а); результат сегментации алгоритмами HECA (б), К-средних (в) и ISODATA (г)

На рисунке 3.10 представлен результат применения алгоритма HECA к мультиспектральному спутниковому изображению. Обработывался фрагмент снимка, полученного со спутника WorldView-2, размера 600×1552 пикселей (рисунок 3.10,а). При сегментации использовалось четыре канала: 2, 3, 5, 7. Задавались следующие параметры алгоритма: $M_{min} = 30$, $L = 8$. Представлены срезы иерархического результата кластеризации на уровнях 0.24 (рисунок 3.10,б), 0.16 (рисунок 3.10,в) и 0.07 (рисунок 3.10,г). Время обработки составило 0.7 с.




Рисунок 3.10 – Изображение со спутника WorldView-2 (RGB-композит, каналы 5, 3, 2) (а); результат его сегментации алгоритмом HECA на различных уровнях иерархии (б-г)

Важным преимуществом алгоритма HECA является его высокая вычислительная эффективность. В таблице 3.1 приведено сравнение времени работы алгоритма HECA и алгоритмов кластеризации из программного пакета ELKI на описанных модельных данных и реальных изображениях (цветное RGB-изображение размера 452×588 пикселей и фрагмент четырехканального изображения размера 250×200 пикселей, полученного со спутника ALOS) [133]. При кластеризации для всех алгоритмов подбирались наиболее оптимальные параметры с точки зрения качества получаемых результатов. Большинство рассматриваемых алгоритмов не позволяют обрабатывать большие массивы данных, поэтому приведены результаты для сравнительно небольших объемов данных.

Предложенный ансамблевый алгоритм HECA обеспечивает высокое качество получаемых результатов и позволяет выделять кластеры разной формы, размера и плотности. Иерархическое представление упрощает интерпретацию результатов кластеризации. Высокая вычислительная эффективность алгоритма позволяет обрабатывать мультиспектральные спутниковые изображения в диалоговом режиме.

Таблица 3.1 – Сравнение времени работы алгоритмов кластеризации (время указано в секундах)

	Модель № 2 $N = 400$ $d = 2$	Модель № 7 $N = 4\,000$ $d = 2$	Модель № 6 $N = 9\,388$ $d = 2$	Спутниковое изображение $N = 50\,000$ $d = 4$	Цветное изображение $N = 265\,776$ $d = 3$
HECA	0.005	0.003	0.055	0.07	0.03
K-means	0.03	0.08	0.06	0.6	1
EM	0.65	18.4	1.45	43	78
DBSCAN	0.06	0.35	1.3	25	136
OPTICS	0.03	0.4	1.8	55	390
DeLiClu	0.19	0.73	2	35	430
SLINK	0.01	0.42	2.2	96	2752

3.8. Краткие выводы по главе

1. В рамках сеточного подхода предложена специальная метрика, основанная на непараметрической оценке плотности распределения. На ее основе разработан вычислительно эффективный иерархический сеточный алгоритм кластеризации НСА.

2. Предложен оригинальный подход к построению ансамбля иерархических разбиений в рамках сеточного подхода. На основе этого подхода разработан ансамблевый алгоритм кластеризации НЕСА, позволяющий повысить устойчивость результатов, получаемых алгоритмом НСА.

3. Проведенные экспериментальные исследования на модельных и реальных данных показали, что алгоритмы НСА и НЕСА позволяют выделять кластеры сложной формы, разного размера и плотности, а также получать иерархическое представление данных и разделять пересекающиеся классы. Приведенное экспериментальное сравнение предложенных алгоритмов с алгоритмами кластеризации, реализованными в программном пакете ELKI, показало их значительное превосходство в скорости работы и качестве результатов. Вычислительная эффективность предложенных алгоритмов позволяет использовать их в диалоговом режиме для обработки мультиспектральных спутниковых изображений.

Глава 4. Комбинирование спектральных и текстурных признаков при сегментации изображений

Применение алгоритмов кластеризации в пространстве спектральных признаков к спутниковым изображениям высокого пространственного разрешения, содержащих текстурные классы (имеющие высокую внутриклассовую спектральную неоднородность), зачастую приводит к получению чрезмерно раздробленных картосхем. На них присутствует множество кластеров, которым не соответствует ни один из реальных (информационных) классов, представляющих интерес для пользователя. Приведенный в первой главе обзор современных исследований показал, что в настоящее время отсутствуют эффективные алгоритмы спектрально-текстурной сегментации мультиспектральных спутниковых изображений. В данной главе предлагается новый метод описания мультиспектральной текстуры и основанный на нем вычислительно эффективный алгоритм спектрально-текстурной сегментации мультиспектральных изображений ESEG.

4.1. Метод описания мультиспектральной текстуры

Применительно к мультиспектральным изображениям текстуру можно интерпретировать как характер распределения векторов спектральных яркостей по полю изображения объекта, обусловленный закономерностями взаимного расположения составляющих объект элементов.

Для большинства объектов природного происхождения (леса, болота, дюны и т.п.) структурные особенности, такие как пространственная ориентация, не являются важными, т.к. пространственная композиция их составных элементов, как правило, имеет случайный характер [134]. При этом количественное содержание составных элементов в локальных областях изображения для текстур одного и того же класса примерно совпадает, а для текстур разных классов отличается. Поэтому для описания естественных текстур целесообразным является использование статистического подхода на основе анализа гистограмм спектральных яркостей [120].

Для описания спектрально-текстурных характеристик областей мультиспектрального изображения предлагается использовать векторы частот встречаемости кластеров, полученных при кластеризации изображения по спектральным признакам. Для первоначальной кластеризации по спектральным признакам предлагается использовать один из

предложенных в диссертации алгоритмов. Полученные «спектральные» кластеры соответствуют некоторому разбиению многомерного пространства спектральных признаков, которое можно рассматривать как специальный способ квантования, позволяющий сократить размер анализируемых характеристик. Выделенные кластеры соответствуют определенным модам плотности спектральных яркостей и могут характеризовать составные элементы объектов изображения. Таким образом, основная идея предлагаемого метода заключается в том, что в локальных областях изображения для мультиспектральных текстур одного и того же класса процентное содержание пикселей из разных «спектральных» кластеров будет примерно одинаково, а для текстур разных классов будет заметно отличаться. Исходя из этой идеи, мультиспектральную текстуру можно описать следующим образом.

Определение 4.1. Пусть картосхема, полученная с помощью кластеризации по спектральным признакам, состоит из K кластеров. Тогда для произвольного фрагмента изображения f определим *вектор спектральных частот* $z(f) = (z^{(1)}, \dots, z^{(K)})$ следующим образом: $\{z^{(i)} = N_f^{(i)} / N_f, i = \overline{1, K}\}$, где N_f – число всех пикселей фрагмента f , $N_f^{(i)}$ – число пикселей фрагмента f , относящихся к кластеру с номером i . Представленные векторы спектральных частот будем рассматривать в качестве спектрально-текстурных признаков для описания мультиспектральной текстуры.

Расстояние между векторами спектральных частот $x = (x^{(1)}, \dots, x^{(K)})$ и $y = (y^{(1)}, \dots, y^{(K)})$ будем определять по формуле $\mu(x, y) = 1 - \sum_{i=1}^K \min(x^{(i)}, y^{(i)})$. При совпадении векторов x и y $\mu(x, y) = 0$, а в случае, если они не имеют общих ненулевых компонент, $\mu(x, y) = 1$. Заметим, что: $\mu(x, y) = 1/2 \cdot \rho(x, y)$, где $\rho(x, y) = \sum_{i=1}^M |x^{(i)} - y^{(i)}|$ – манхэттенская метрика (расстояние городских кварталов). Эта метрика часто используется при сравнении гистограмм [110, 112].

4.2. Алгоритм спектрально-текстурной сегментации ESEG

Предлагаемый алгоритм ESEG(h, R), где h – размер фрагментов, R – порог объединения, позволяет выполнять спектрально-текстурную сегментацию изображений с использованием введенных векторов спектральных частот.

Входными данными являются: картосхема изображения, состоящая из N пикселей и K кластеров, и параметры h, R . Алгоритм ESEG состоит из трех основных шагов.

Шаг 1. Формирование векторов спектральных частот. Исходная картосхема разбивается на множество непересекающихся фрагментов размера $h \times h$ пикселей (на краях изображения возможно появление прямоугольных фрагментов меньшего размера): $\{f_1, \dots, f_M\}$, где число фрагментов $M \approx N/h^2$. Для всех фрагментов вычисляются соответствующие векторы спектральных частот $\{z_1, \dots, z_M\}$ (согласно определению 4.1).

Шаг 2. Кластеризация векторов $\{z_1, \dots, z_M\}$ с помощью алгоритма CLUSTER с параметром R . Пиксели фрагментов изображения относятся к тем кластерам, к которым были отнесены соответствующие им векторы спектральных частот.

Шаг 3. Попиксельная коррекция границ кластеров. Последовательно рассматриваются границы смежных фрагментов, отнесенных к разным кластерам. Каждый пиксель, попадающий на границу, относится к тому из соседних кластеров, к центру которого окажется ближе вектор спектральных частот фрагмента размера $h \times h$ с центром в рассматриваемом пикселе. При этом могут появиться новые граничные пиксели. Процесс продолжается до тех пор, пока все граничные пиксели не будут рассмотрены.

Алгоритм кластеризации CLUSTER($\{z_1, \dots, z_M\}, R$) [26], используемый для группировки векторов спектральных частот, состоит из трех основных шагов.

Шаг 1. Формирование списка центров кластеров $S = \{c_i\}$. Изначально в список помещается вектор $z_1 \rightarrow S$, как центр одноэлементного кластера. Затем последовательно рассматриваются остальные векторы $z_i, i = \overline{2, M}$. Если для рассматриваемого вектора z_i существует центр $c_j \in S$ на расстоянии менее R ($\mu(z_i, c_j) < R$), то центр кластера c_j пересчитывается (как среднее значение по всем элементам кластера с добавлением нового элемента z_i). В противном случае вектор добавляется в список центров $z_i \rightarrow S$, как центр нового одноэлементного кластера.

Шаг 2. Объединение близких центров. Все пары центров $\{(c_i, c_j), i < j\}$, находящихся на расстоянии менее чем R ($\mu(c_i, c_j) < R$), объединяются в один центр, соответствующий центру тяжести элементов этих кластеров.

Шаг 3. Классификация всех входных векторов $z_i, i = \overline{1, M}$ путем отнесения их к ближайшему из центров: $\arg \min_{c_j \in \{c_i\}} \mu(z_i, c_j)$.

Вычислительная сложность представленного алгоритма сегментации ESEG линейно зависит от числа пикселей изображения N . Параметр h определяет размер фрагментов, описывающих текстуру. Параметр R определяет степень детальности разбиения. В проведенных экспериментах оптимальное значение параметра R практически всегда было равно 0.4.

4.3. Экспериментальное исследование алгоритма ESEG

Алгоритм ESEG исследовался на модельных и реальных данных. В данном разделе представлены результаты обработки двух модельных изображений, цветного изображения и трех спутниковых снимков высокого пространственного разрешения.

Модельное изображение № 1. Обработывалось цветное модельное изображение (рисунок 4.1,а), составленное из шести различных цветных текстур. Размер изображения составляет 938×622 пикселя. Наличие общих цветов у различных текстур делает невозможным получение корректной сегментации с использованием только спектральных признаков. Для предварительной кластеризации по спектральным признакам использовался алгоритм HECA с параметрами $M_{min} = 18$, $L = 8$. Срез иерархического результата осуществлялся на максимально подробном уровне ($cut = 0$). На рисунке 4.1,б представлен результат сегментации данного изображения алгоритмом ESEG при $h = 35$ и $R = 0.4$. Алгоритм позволил выделить все шесть классов с точностью 99.72%. При этом время работы алгоритма HECA составило 0.06 с, а алгоритма ESEG – 0.05 с.




Рисунок 4.1 – Модельное изображение № 1 (а); результат сегментации алгоритмом ESEG (б)

Модельное изображение № 2. На рисунке 4.2,а представлено модельное изображение, составленное из пяти цветных текстур. При этом две соседние текстуры (верхняя левая и верхняя правая) имеют одинаковый средний цвет, что делает невозможным их разделение с помощью методов на основе осреднения цветов. Размер изображения составляет 622×622 пикселя. Для предварительной сегментации по спектральным признакам использовался алгоритм кластеризации НЕСА с параметрами $M_{min} = 18$, $L = 8$ и срезом иерархического результата на уровне $cut = 0$. На рисунке 4.2,в представлен результат сегментации данного изображения с помощью алгоритма ESEG при $h = 35$ и $R = 0.5$. Алгоритм позволил выделить все пять классов с точностью 99.5%. Время работы алгоритма НЕСА составило 0.05 с, а алгоритма ESEG – 0.06 с. На рисунке 4.2,б представлен промежуточный результат сегментации (без коррекции границ кластеров). В этом случае точность сегментации составляет 97.0%.




Рисунок 4.2 – Модельное изображение № 2 (а); результат сегментации алгоритмом ESEG до (б) и после коррекции границ (в)

На рисунке 4.3,а представлено цветное изображение размера 600×450 пикселей. Для предварительной сегментации по спектральным признакам использовался алгоритм НЕСА с параметрами $M_{min} = 18$, $L = 8$ и срезом иерархического результата на уровне $cut = 0.2$ (рисунок 4.1,б). При сегментации алгоритмом ESEG использовались параметры: $h = 25$ и $R = 0.4$. Алгоритм позволил выделить на изображении следующие объекты: гепард, трава, небо и деревья на заднем плане. Время работы НЕСА составило 0.04 с, а алгоритма ESEG – 0.03 с.




Рисунок 4.3 – Исходное изображение (а); результат сегментации алгоритмами ECCA (б) и ESEG (в)

На рисунке 4.4 представлен результат сегментации мультиспектрального спутникового изображения высокого пространственного разрешения. Обработывался фрагмент снимка, полученного со спутника WorldView-2 (рисунок 4.4,а). Размер изображения – 621×2048 пикселей. Для предварительной сегментации по спектральным признакам использовался алгоритм ECCA с параметрами $M_{min} = 18$, $L = 8$, $T = 0.9$ и срезом иерархического результата на уровне $cut = 0.2$ (рисунок 4.4,б). При обработке использовались каналы: 3, 4, 7. При этом возникает существенная раздробленность информационного класса «лес» из-за его высокой спектральной неоднородности. Предложенный алгоритм ESEG позволил устранить раздробленность картосхемы и корректно выделить все информационные классы (рисунок 4.4,в). Задавались следующие параметры алгоритма: $h = 11$, $R = 0.4$. Время работы алгоритма ECCA составило 0.1 с, а алгоритма ESEG – 0.14 с.

Для оценки качества результатов сегментации для данного спутникового изображения методом визуально-инструментального дешифрирования была построена картосхема информационного класса «лес» (рисунок 4.4,г). Классу «лес» ставился в соответствие один из полученных при сегментации кластеров (имеющий наибольшее пересечение), при этом остальные кластеры относились к классу-фону. Точность сегментации определялась как процент правильно расклассифицированных пикселей.

В таблице 4.1 представлена точность результатов сегментации, полученных с помощью алгоритма ESEG при различных значениях параметра h . Наблюдается сильная зависимость точности от изменения параметра. Это связано с тем, что при слишком малом значении параметра h текстура классов может быть не выявлена, а при слишком большом – снижается точность выделения объектов и теряются мелкие детали.




Рисунок 4.4 – Изображение со спутника WorldView-2 (RGB-композит, каналы 4, 7, 3) (а);
результаты сегментации алгоритмами ECCA (б) и ESEG (в);
картосхема класса «лес» (выделен зеленым цветом) (г)

Для снижения зависимости результатов работы алгоритма ESEG от значения параметра h предлагается осуществлять выявление текстур с помощью достаточно крупных фрагментов, при этом производить сегментацию изображения с помощью более мелких фрагментов. Для этого вводится дополнительный параметр h_L , и в процессе сегментации используются два различных разбиения на фрагменты размеров $h \times h$ и $h_L \times h_L$. Алгоритм ESEG модифицируется следующим образом. На первом шаге производится формирование векторов спектральных частот для двух разбиений на фрагменты: $\{z_1, \dots, z_M\}$ и $\{z_1^{(L)}, \dots, z_{M_L}^{(L)}\}$. В процессе кластеризации векторов алгоритмом CLUSTER формирование списка центров кластеров осуществляется по набору

$\{z_1^{(L)}, \dots, z_{M_L}^{(L)}\}$, затем классифицируются векторы спектральных частот $\{z_1, \dots, z_M\}$. На заключительном этапе производится попиксельная коррекция границ кластеров для разбиения на фрагменты, соответствующие параметру h .

Предложенный подход позволяет уменьшить допустимое значение размера фрагмента h и при этом повысить точность сегментации. В таблице 4.1 представлена зависимость точности сегментации спутникового изображения (рисунок 4.4,а) оригинальным и модифицированным алгоритмом $ESEG_L(h, h_L, R)$ с параметрами $h_L = 15$, $R = 0.4$ от значения параметра h . Результаты, которые также отображены на графике (рисунок 4.5), демонстрируют повышение точности и устойчивости сегментации для модифицированной версии алгоритма $ESEG_L$.

Таблица 4.1 – Зависимость точности сегментации спутникового изображения алгоритмом ESEG и его модификацией $ESEG_L$ от значения параметра h , %

h	3	4	5	6	7	8	9	10	11
$ESEG(h, 0.4)$	90.44	92.48	94.94	95.63	96.50	96.75	93.43	97.10	97.18
$ESEG_L(h, 15, 0.4)$	96.69	97.44	97.88	97.98	97.90	97.78	97.58	97.46	97.24

Продолжение таблицы 4.1.

h	12	13	14	15	16	17	18	19	20
$ESEG(h, 0.4)$	97.01	96.88	93.20	96.62	96.61	96.39	90.91	95.87	95.91
$ESEG_L(h, 15, 0.4)$	97.02	96.87	96.74	96.62	96.49	96.38	96.05	95.98	96.00




Рисунок 4.5 – Зависимость точности сегментации спутникового изображения от значения параметра h для алгоритма ESEG и его модификации $ESEG_L$

На рисунке 4.6,а представлен фрагмент спутникового снимка Карадагского природного заповедника (юго-восточная часть Крыма), полученного со спутника WorldView-2. Размер изображения составляет 3608×3478 пикселей. Для предварительной сегментации по спектральным признакам использовался алгоритм кластеризации ЕССА с параметрами $M_{min} = 32$, $L = 8$, $T = 0.9$ и срезом иерархического результата на уровне $cut = 0$. При обработке использовались четыре спектральных канала: 2, 3, 5, 6. Спектрально-текстурная сегментация изображения производилась алгоритмом $ESEG_L$ с параметрами $h = 12$, $h_L = 15$, $R = 0.4$. Время работы алгоритма ЕССА составило 2.4 с, алгоритма $ESEG_L$ – 6.7 с. На основе полученных результатов сегментации и данных полевых исследований была составлена карта растительного покрова (рисунок 4.6,б), на которой выделены лесные массивы разного породного состава и различной степени сомкнутости.

Использование только спектральных признаков для сегментации рассматриваемого изображения приводит к чрезвычайно раздробленным картосхемам (рисунок 4.6,в), не представляющим большого интереса. Повысить качество получаемых картосхем в данном случае возможно с помощью алгоритмов сглаживания. На рисунке 4.6,г представлен результат сегментации изображения алгоритмом ЕССА с предварительным применением сглаживания (простого усреднения с квадратным окном размера 11×11 пикселей). В результате были выделены кластеры, соответствующие лесу разной степени сомкнутости. Однако, в отличие от результатов спектрально-текстурной сегментации, такой подход не позволил различить породный состав леса и выделить следующие классы: скальнодубово-ясеновый лес, разреженный пушистодубовый шибляк на южных склонах и сосновые посадки.




Рисунок 4.6 – Изображение со спутника WorldView-2 (RGB-композит, каналы 5, 3, 2) (а); результат спектрально-текстурной сегментации алгоритмом $ESEG_L$ (б) (1 – сосновые посадки; 2 – густосомкнутый скальнодубово-ясеневый лес; 3 – разреженный пушистодубовый шибляк на южных склонах, сомкнутость 0.5; 4 – пушистодубовый шибляк, сомкнутость 0.8; 5 – сомкнутый пушистодубовый лес; 6 – густосомкнутый пушистодубовый лес; 7 – нитрофильная рудеральная растительность; 8 – виноградники; 9 – пустошь, виноградники; 10 – скалы; 11 – вода); результаты сегментации алгоритмом ECCA без и с предварительным сглаживанием (в, г)

4.4. Сегментация спутниковых изображений с учетом тематических масок

Предложенный алгоритм сегментации ESEG показал хорошие результаты при выделении различных типов растительности. Однако искусственные объекты, такие как здания, сооружения и дороги, при спектрально-текстурной сегментации выделяются недостаточно точно. В сочетании с окружающими объектами они могут быть распозна-

ны как текстурные классы, что приводит к размыванию их границ. Поэтому для их эффективного выделения целесообразно использовать специализированные методы [135].

На основе предложенного алгоритма ESEG разработана многоэтапная схема сегментации спутниковых изображений высокого пространственного разрешения, позволяющая учитывать предварительно выделенные объекты. На первом этапе производится сегментация по спектральным признакам алгоритмом ECCA. На втором этапе осуществляется выделение определенных объектов с помощью специализированных методов (возможно с использованием результатов алгоритма ECCA). Затем формируется пространственная маска всех выделенных объектов. На заключительном этапе выполняется спектрально-текстурная сегментация изображения с исключением выделенных объектов. При этом в процессе выполнения алгоритма ESEG при вычислении векторов спектральных частот учитываются только те пиксели фрагментов, которые не попадают под построенную маску. После выполнения спектрально-текстурной сегментации скрытые маской объекты включаются в окончательную картосхему в качестве отдельных кластеров.

На рисунке 4.7 представлен пример сегментации изображения, полученного со спутника WorldView-2. Размер изображения составляет 2048×2048 пикселей. На снимке были предварительно выделены следующие объекты: водная поверхность, песок и искусственные объекты (здания, сооружения, дороги). Для выделения водной поверхности использовался нормализованный разностный водный индекс (NDWI) [136]. Здания и дороги были выделены с помощью метода определения границ антропогенных объектов [137]. С помощью уже выделенных объектов и нормализованного разностного вегетационного индекса (NDVI), позволяющего отделять не покрытые растительностью территории, был также выделен песок. Из выделенных объектов была сформирована маска, представленная на рисунке 4.7,б.

Сегментация по спектральным признакам выполнялась алгоритмом ECCA с параметрами $M_{min} = 18$, $L = 8$, $T = 0.9$ (рисунок 4.7,в). При обработке использовались каналы: 1, 3, 4, 6. В результате была получена картосхема, содержащая 52 кластера, для большинства из которых нет соответствия среди реальных объектов. На рисунке 4.7,г представлен результат сегментации изображения алгоритмом $ESEG_L$ с учетом сформированной маски. Задавались следующие параметры алгоритма: $h = 10$, $h_L = 15$, $R = 0.4$. Время работы алгоритма ECCA составило 0.4 с, а алгоритма ESEG – 0.3 с.




Рисунок 4.7 – Пример сегментации спутникового снимка WorldView-2: (а) RGB-композит исходного изображения (каналы 5, 3, 2); (б) маска водной поверхности, зданий, дорог и песка; (в) результат сегментации алгоритмом ECCA; (г) результат сегментации алгоритмом ESEG с учетом маски выделенных объектов (1 – лесные территории; 2 – трава; 3 – незасеянные поля и пустоши; 4 – сельскохозяйственные посевы; 5 – водная поверхность; 6 – здания, сооружения, дороги; 7 – песок)

Экспериментальные исследования на модельных и реальных изображениях показали, что предложенный алгоритм спектрально-текстурной сегментации является вычислительно эффективным и обеспечивает выделение текстурных классов на мультиспектральных спутниковых изображениях высокого пространственного разрешения.

4.5. Краткие выводы по главе

1. Предложен новый метод описания мультиспектральной текстуры, не требующий введения единой метрики в пространстве разнородных спектрально-текстурных признаков. В рамках этого подхода разработан вычислительно эффективный алгоритм спектрально-текстурной сегментации изображений ESEG.

2. Экспериментальные исследования алгоритма ESEG на модельных и реальных изображениях подтвердили вычислительную эффективность предложенного алгоритма и его способность выделять текстурные классы на мультиспектральных изображениях.

3. На основе алгоритма ESEG предложена многоэтапная схема сегментации спутниковых изображений высокого пространственного разрешения, позволяющая учитывать объекты, выделенные с помощью различных специализированных методов.

Глава 5. Программное обеспечение на основе разработанных алгоритмов и решение практических задач

5.1. Программный комплекс «ЕССА-Pack» для сегментации мультиспектральных изображений

В рамках диссертационной работы было создано программное приложение (прикладное программное обеспечение) «ЕССА-Pack», предназначенное для сегментации мультиспектральных спутниковых изображений. Оно реализовано на языке программирования Java и включает в себя представленные в диссертации алгоритмы кластеризации и сегментации, а также метод автоматического выделения водных объектов, представленный в разделе 5.2, и разработанный автором метод автоматического выделения теней [138]. Кроме того, разработанное приложение предоставляет пользователю средства предварительной обработки изображений, визуализации данных и результатов сегментации.

Графический пользовательский интерфейс приложения «ЕССА-Pack» представлен на рисунке 5.1.




Рисунок 5.1 – Графический пользовательский интерфейс приложения «ЕССА-Pack»

В интерфейсе программы выделяются следующие основные компоненты.

1. Меню.
2. Область просмотра изображений.
3. Шкала выбора уровня иерархии.
4. Блок запуска алгоритмов сегментации.
5. Блок выбора действия, выполняемого при клике мыши.
6. Блок настройки визуализации результатов кластеризации.
7. Блок методов выделения определенных объектов.
8. Блок информации.

В приложении можно выделить пять функциональных блоков (рисунок 5.2).



Рисунок 5.2 – Схема взаимодействия основных функциональных блоков программного приложения «ЕССА-Pack»

1. *Блок работы с файлами* предназначен для загрузки и сохранения данных. Пользователю доступны как распространенные форматы изображений (PNG, JPEG, BMP, GIF), так и специализированные форматы для мультиспектральных изображений с географической привязкой (GeoTIFF, ENVI standard и Erdas Imagine Images). Для работы с растровыми географическими форматами файлов данных используется библиотека GDAL (Geospatial Data Abstraction Library) [139]. При открытии файла пользователю

предлагается выбрать каналы изображения, которые будут загружены и использованы при дальнейшей обработке, а также выбрать каналы, из которых будет синтезирован RGB-композит для визуализации изображения.

2. *Блок предварительной обработки* включает функции обработки изображений, применяемые до выполнения основных методов сегментации. В него входят: процедура линейного растяжения динамического диапазона спектральных яркостей с отсечением заданного процента «хвостов» гистограммы и прямоугольный сглаживающий фильтр.

3. *Блок визуализации* позволяет настраивать параметры отображения загруженного изображения и результатов сегментации. Пользователю доступен выбор каналов, используемых при формировании RGB-композита. Кроме того, имеется возможность настройки цветовой палитры картосхемы вплоть до отдельных кластеров (задание «средних», случайных, контрастных или пользовательских цветов для кластеров).

4. *Блок сегментации* включает алгоритмы кластеризации по спектральным признакам (ССА, ЕССА, НСА и НЕСА) алгоритм спектрально-текстурной сегментации (ESEG_L) и методы автоматического выделения водных объектов и теней. Реализована возможность обработки отдельных фрагментов изображения в рамках уже построенной картосхемы с применением любого из реализованных алгоритмов кластеризации.

5. *Блок работы с картосхемой* предназначен для обработки результатов сегментации. Шкала выбора уровня иерархии позволяет настраивать параметр среза дендрограммы при визуализации иерархических результатов кластеризации или же задавать желаемое число классов напрямую. Кроме того, имеется возможность настраивать желаемый уровень детализации для каждого кластера. В режиме «информация» кликом мыши можно получить статистические характеристики классов.

Разработанное программное приложение снабжено руководством пользователя, содержащим всю необходимую информацию для корректной настройки и работы программы, описание ее функционала, возможностей и ограничений [140].

Разработанные алгоритмы и программное обеспечение использовались для решения ряда практических задач, две из которых подробно рассмотрены далее.

5.2. Автоматическое выделение водных объектов на спутниковых изображениях высокого разрешения для оперативного мониторинга паводковой ситуации

Паводковая обстановка на реках Сибирского федерального округа является одной из острых проблем и требует постоянного мониторинга. Оперативное наблюдение за обширными территориями потенциальных зон затопления возможно лишь с использованием данных дистанционного зондирования Земли. Получаемые с их помощью карты паводковой обстановки являются одним из основных источников информации для региональных служб МЧС при принятии решений. Однако выделение границ и площадей подтоплений по данным ДЗЗ «ручными» (визуально-инструментальными) методами требует значительных трудозатрат.

В настоящее время известен целый ряд методов выделения водных объектов по данным оптической спутниковой съемки [141]: 1) пороговые методы с использованием определенного спектрального канала или комплексного спектрального признака (индекса) [136, 142, 143]; 2) пороговое дерево решений на основе заданных спектральных характеристик [141]; 3) классификация с обучением [144]; 4) использование алгоритмов кластеризации [144, 145] и др. Однако применение этих методов для выделения водных объектов на снимках высокого пространственного разрешения, полученных с отечественных спутников Каноус-В и Ресурс-П, в оперативной работе оказалось неудовлетворительным [144]: к водным объектам часто относились переувлажненные почвы, тени от облаков, некоторые антропогенные объекты.

На основе предложенного во второй главе алгоритма кластеризации ЕССА был разработан новый двухэтапный метод автоматического выделения водных объектов на мультиспектральных спутниковых снимках.

Этап 1. Сегментация изображения по спектральным признакам с помощью алгоритма кластеризации ЕССА. При кластеризации используются красный и ближний инфракрасный каналы, а также вегетационный индекс NDVI. Экспериментальные исследования показали, что данная комбинация признаков является наиболее эффективной при выделении водных объектов. Задаются следующие параметры алгоритма ЕССА: $L = 8_{(2)}$, $T = 0.9$. Параметр сетки M_{min} и уровень среза иерархии подбираются автоматически, обеспечивая разбиение изображения на 40–50 кластеров. В результате все водные объекты выделяются в один или несколько кластеров.

Этап 2. Разделение полученных кластеров на «водные» и «неводные». Для этого используется построенное в ходе исследований дерево решений (рисунок 5.3). Для каждого кластера вычисляются средние значения пяти характеристик: индексов NDWI [136] и NDVI, а также нормированных на диапазон $[0, 255]$ значений яркости в красном и ближнем инфракрасном каналах и индекса NDVI. Использование средних значений характеристик кластеров позволяет повысить качество разделения пороговым методом. В результате множество всех кластеров разбивается на три класса: 1) «вода», 2) «переувлажненные почвы», 3) «неводные» классы.




Рисунок 5.3 – Дерево решений для разделения кластеров на «водные» и «неводные»

В отличие от известных методов, предложенный подход позволяет выделять водные объекты на изображениях не только низкого и среднего, но и высокого (2-10 м) пространственного разрешения. При этом время обработки спутниковых изображений размером десятки миллионов пикселей составляет всего несколько секунд.

На рисунках 5.4 и 5.5 приведены примеры обработки изображений, полученных со спутника Канопус-В.




Рисунок 5.4 – Фрагмент изображения, полученного со спутника Канопус-В 13 апреля 2014 г (RGB-композит, каналы 3, 2, 1) (а); результат выделения водной поверхности (обозначена синим цветом) и «переувлажненных почв» (обозначены красным цветом) (б)




Рисунок 5.5 – Фрагмент изображения, полученного со спутника Канопус-В 25 июня 2014 г (RGB-композит, каналы 3, 4, 2) (а); результат выделения водной поверхности (осиний цвет) (б)

Получаемые с помощью разработанного метода результаты сегментации служат основой для построения тематических карт паводковой обстановки, содержащих информацию о границах выхода воды на пойму. Пример карты паводковой обстановки, построенной по данным со спутника Канопус-В, приведен на рисунке 5.6.




Рисунок 5.6 – Карта паводковой обстановки

Предложенный метод позволяет в оперативном режиме обрабатывать спутниковые данные с отечественных космических аппаратов Ресурс-П и Канопус-В и строить карты паводковой обстановки. Кроме этого, в результате мониторинга формируется база данных, содержащая векторные данные участков подтопления и позволяющая вести временной анализ паводковой ситуации. Разработанный метод программно реализован в приложении «ЕССА-Раск» и используется в отделе обработки спутниковой информации Сибирского центра ФГБУ «НИЦ «Планета» при создании карт паводковой обстановки для потребителей Росгидромета и региональных служб МЧС, что подтверждено актом внедрения (см. Приложение 4).

5.3. Крупномасштабное моделирование структуры степной растительности с использованием снимков высокого разрешения

Картографическое моделирование растительного покрова является одним из фундаментальных и приоритетных направлений современной науки о растительности. Оно опирается на большой объем фактических данных и новые разработки в области геоинформационных технологий [146]. Традиционно для картографического моделирования растительности широко используются спутниковые изображения низкого и

среднего пространственного разрешения (NOAA/AVHRR, Terra+Aqua/MODIS, Landsat, SPOT). В последние годы, благодаря возросшей доступности снимков высокого разрешения и новым методам их обработки, открываются возможности детального изучения закономерностей формирования растительного покрова и обнаружения местообитаний редких и уникальных видов растений. Эта возможность очень актуальна при картографическом моделировании степной растительности горно-степных районов, т.к. представленные там сообщества зачастую имеют небольшие размеры, их растительный покров характеризуется высокой гетерогенностью и образует сложную мозаику, обусловленную различным сочетанием эколого-топографических факторов на которые растительность откликается изменением видового состава.

В настоящее время для территории Южной Сибири существуют карты среднего и мелкого масштаба, отражающие основные закономерности пространственной структуры зональных типов растительности высокого ранга, в то время как важные закономерности формирования растительности на ландшафтном уровне остаются не раскрыты. Снимки среднего разрешения позволяют исследовать растительность только на уровне сочетаний сообществ, что не дает возможности разносторонне изучить и отобразить не только полное разнообразие растительности, но и причины формирования пространственных структур. При анализе спутниковых изображений высокого разрешения размер описываемых площадок ($10 \times 10 \text{ м}^2$) превосходит размер пикселя изображения приблизительно в 25 раз, что позволяет строить картографические модели актуальной растительности и отображать ее на уровне фитоценозов.

Объектом данного исследования являлась естественная степная растительность на территории Ширинского района (Северо-Минусинская межгорная котловина) в окрестностях озера Иткуль. Абсолютные высоты территории колеблются в диапазоне от 540 до 650 метров, координаты центра ключевого полигона – $54^\circ 28' 08.96''$ с.ш.; $90^\circ 08' 36.34''$ в.д. Исследуемая территория расположена между крупными горными системами: Кузнецкое Алатау на западе, Западный Саян с южной стороны котловины и Восточный Саян окаймляет восточную часть. Рельеф территории представлен плоскими или волнистыми формами. Территория котловины расположена в дождевой тени Кузнецкого Алатау и характеризуется ультраконтинентальным климатом, который проявляется в резко выраженных изменениях температуры воздуха по сезонам года, месяцам и суткам.

Исследования проводились с использованием 110 геоботанических описаний степной растительности, выполненных по стандартной методике на площадках $10 \times 10 \text{ м}^2$ в период 2012-2013 годы [147]. На основе геоботанических описаний была создана база данных с использованием пакета TURBO(VEG) [148]. Определение типов сообществ для отображения при картировании выполнено в рамках эколого-флористического подхода [149]. Флоро-фитоценотическая целостность выделенных единиц протестирована методом градиентного анализа, реализованного в специализированном пакете DECORANA [150].

Исследование разнообразия пространственной организации растительного покрова выполнялось с использованием восьмиканального снимка высокого пространственного разрешения, полученного со спутника WorldView-2 (рисунок 5.7,а). Обработка изображения осуществлялась в два этапа.

На первом этапе обработки по изображению ключевого участка вычислялась корреляционная матрица R , верхний треугольник которой имеет вид:

$$R = \begin{pmatrix} 1.00 & 0.98 & 0.92 & 0.95 & 0.96 & 0.08 & -0.28 & -0.26 \\ & 1.00 & 0.94 & 0.97 & 0.96 & 0.13 & -0.23 & -0.21 \\ & & 1.00 & 0.98 & 0.97 & 0.41 & 0.04 & 0.06 \\ & & & 1.00 & 0.99 & 0.29 & -0.09 & -0.06 \\ & & & & 1.00 & 0.21 & -0.17 & -0.15 \\ & & & & & 1.00 & 0.91 & 0.92 \\ & & & & & & 1.00 & 0.99 \\ & & & & & & & 1.00 \end{pmatrix}.$$

Анализ корреляционной матрицы показал, что некоторые компоненты вектора спектральных яркостей имеют сильную взаимную корреляцию. Это означает, что часть каналов не несет полезной информации и их использование лишь усложнит процесс обработки. В связи с этим был осуществлен выбор минимального набора признаков, обеспечивающего необходимое качество классификации.

Для классификации растительности целесообразно одновременно использовать спектральные каналы 3 (510-580 нм) и 4 (585-625 нм), а также 6 (705-745 нм), который позволяет оценить состояние здоровья растительного покрова [151]. Каналы из ближнего инфракрасного диапазона спектра (7 и 8) реагируют на изменение структуры мезофилла (листовой мякоти зеленых растений), однако 7-й канал (770-895 нм) более

чувствителен к типу подстилающей поверхности, чем 8-й (860-1040 нм). Таким образом, для сегментации изображения были выбраны каналы 3, 4, 6 и 7.

На втором этапе по выбранному набору признаков выполнялась сегментация изображения с помощью алгоритма кластеризации ЕССА, предложенного во второй главе. В результате была построена крупномасштабная картосхема, фрагмент которой представлен на рисунке 5.7,б. Она позволяет описать сложную структуру и обнаружить важные закономерности формирования степных растительных сообществ с участием редких, эндемичных и уникальных видов.




Рисунок 5.7 – Изображение со спутника WorldView-2 (RGB-композит, каналы 5, 3, 2) (а); крупномасштабная картосхема ключевого полигона, полученная с помощью кластеризации алгоритмом ЕССА (1 – *Androsaco dasyphyllae*-*Caricetum pediformis* и субассоциация *A.d.-C.p. helictotrichetosum desertorum*; 2 – *Youngio tenuifoliae*-*Agropyrietum cristati*; 3 – *Artemisio glaucae*-*Caricetum pediformis*; 4 – *Thalictro foetidi*-*Festucetum valesiacaе*; 5 – *Achnathero sibirici*-*Stipetum krylovii*) (б)

Структура степей образована закономерным сочетанием растительных сообществ, обусловленным особенностями рельефа ключевого участка, а также связанными с ним экологическими и эдафическими факторами. Было выделено две мезокомбинации. Первая представляет собой сочетание сообществ петрофитных и непетрофитных степей в ландшафте с хорошо выраженным грядовым комплексом. В ней можно выделить микрокомбинации, которые различаются по приуроченности к экспозиции склона и представляют собой микропоясные ряды сообществ.

Первый микропоясный ряд характерен для наиболее крутых склонов южных, юго-западных и юго-восточных экспозиций. Микропоясный ряд начинается с комплекса

осоково-кобрезиевых петрофитных степей (*Androsaco dasyphyllae*-*Caricetum pediformis*) с участием гляциальных реликтовых (*Kobresia filifolia*, *Minuartia verna*, *Sagina saginoides*, *Androsae dasyphylla*), а также редких и эндемичных (*Phlox sibirica*, *Oxytropis chakassiensis*) видов. Ниже по склону степи с участием криофитов замещаются доминирующими здесь злаково-разнотравными петрофитными степями (*Youngio tenuifoliae*-*Agropyrietum cristati*) с участием редких видов (*Adenofora rupestris*, *Oxytropis includens*, *O. nuda*, *O. ammophila*). В нижних пологих частях южных склонов, а также по их шлейфам, на хорошо развитых почвах распространены сообщества овсяницево-разнотравных степей (*Thalictro foetidi*-*Festucetum valesiacaе*) с участием видов, занесенных в Красную Книгу Хакасии (*Carex humilis*, *Lilium pumilum*) и их кустарниковых вариантов с *Caragana pygmaea*.

Второй микропоясный ряд расположен на более пологих склонах северных экспозиций. Их верхние части занимают более мезофильные варианты осоково-кобрезиевых степей (*Androsaco dasyphyllae*-*Caricetum pediformis helictotrichetosum desertorum*). Ниже по северному склону располагаются петрофитные мезоксерофитные полынно-осоково-разнотравные степи (*Artemisio glaucae*-*Caricetum pediformis*). Средние части склонов заняты преимущественно сочетанием сообществ умеренно влажных непетрофитных осоково-разнотравных (*Pulsatillo patentis*-*Caricetum pediformis*) и овсецово-разнотравных (*Bupleuro multinervi*-*Helictotrichetum desertorum*) степей с участием видов, занесенных в Красную книгу Хакасии и Красную книгу РФ (*Stipa pennata*, *S. zalesski*). Эти типы степей преобладают на большинстве северных склонов, вплоть до шлейфов.

Вторая мезокомбинация занимает плоские или слабовогнутые широкие части рельефа, расположенные между грядами. Здесь структура степной растительности представлена сочетанием ксеромезофитных разнотравно-злаковых (*Achnathero sibirici*-*Stipetum krylovii*) и разнотравных (*Thalictro foetidi*-*Festucetum valesiacaе*) степей, распространенных на хорошо развитых почвах.

Таким образом, разработанный алгоритм ЕССА позволил построить крупномасштабную картосхему по снимку высокого пространственного разрешения WorldView-2 и произвести моделирование пространственной организации степной растительности. Продемонстрированы закономерности формирования растительного покрова горно-степного пояса и представлено четкое очертание контуров на уровне отдельных

фитоценозов. Полученные результаты имеют большое значение для охраны уникальных реликтовых сообществ и произрастающих в них редких и уникальных видов растений, а также мониторинга сохранившихся естественных степных участков в целом. Это особенно актуально при исследовании степей Южной Сибири, которые не включены в территории заповедников и подвержены сильному антропогенному воздействию.

5.4. Краткие выводы по главе

1. На основе разработанных автором методов и алгоритмов создано прикладное программное обеспечение «ЕССА-Риск», предназначенное для обработки и анализа мультиспектральных спутниковых изображений.
2. Разработан новый вычислительно эффективный метод автоматического выделения водных объектов на мультиспектральных спутниковых изображениях высокого пространственного разрешения на основе алгоритма кластеризации ЕССА. Разработанный метод используется в Сибирском центре ФГБУ «НИЦ «Планета» при создании оперативных карт паводковой обстановки по данным с отечественных космических аппаратов Ресурс-П и Канопус-В для потребителей Росгидромета и региональных служб МЧС.
3. Разработанные алгоритмы кластеризации позволили выполнить крупномасштабное моделирование структуры степной растительности по спутниковым снимкам высокого пространственного разрешения.

Заключение

В диссертационной работе получены следующие основные результаты.

1. Разработан и исследован новый сеточный алгоритм кластеризации ССА, позволяющий выделять многомодовые кластеры разной формы, размера и плотности. Показана линейная зависимость времени работы алгоритма от числа элементов обрабатываемых данных. Вычислительная эффективность алгоритма ССА позволяет обрабатывать мультиспектральные спутниковые изображения большого размера (до 100 миллионов пикселей) в диалоговом режиме.
2. Впервые предложен подход к построению ансамбля сеточных алгоритмов кластеризации с помощью согласованной матрицы различий. В рамках этого подхода создан ансамблевый алгоритм кластеризации ЕССА, позволяющий значительно повысить устойчивость результатов работы алгоритма ССА к изменению значений его параметров. Проведенные экспериментальные исследования показали, что алгоритм ЕССА обеспечивает высокое качество получаемых результатов, а его вычислительная эффективность позволяет обрабатывать мультиспектральные спутниковые изображения в диалоговом режиме.
3. Для построения иерархического алгоритма кластеризации в рамках сеточного подхода предложена специальная метрика, основанная на непараметрической оценке плотности распределения. На ее основе разработан и исследован иерархический сеточный алгоритм кластеризации НСА. В отличие от известных иерархических алгоритмов, НСА позволяет разделять пересекающиеся кластеры и обладает линейной вычислительной сложностью, что обеспечивает возможность его применения для сегментации спутниковых изображений большого размера. Получаемое при этом иерархическое представление результатов существенно упрощает их интерпретацию.
4. Предложен оригинальный способ построения ансамбля иерархических разбиений в рамках сеточного подхода. По сравнению с известными методами формирования ансамбля иерархических разбиений, предложенный подход является вычислительно эффективным и применим для обработки мультиспектральных спутниковых

изображений. На основе этого подхода создан ансамблевый алгоритм кластеризации НЕСА, позволяющий значительно повысить устойчивость получаемых результатов работы алгоритма НСА. Проведенные экспериментальные исследования показали существенное превосходство НЕСА в скорости работы и качестве получаемых результатов по сравнению с известными алгоритмами кластеризации.

5. Предложен новый метод описания мультиспектральной текстуры, не требующий введения единой метрики в пространстве разнородных спектрально-текстурных признаков. С помощью этого метода разработан вычислительно эффективный алгоритм спектрально-текстурной сегментации изображений (ESEG), предназначенный для обработки мультиспектральных спутниковых изображений высокого пространственного разрешения. На основе алгоритма ESEG разработана многоэтапная схема сегментации спутниковых изображений высокого разрешения, предназначенная для исследования природных и антропогенных объектов.
6. Создан комплекс программ «ЕССА-Pack» для обработки и анализа мультиспектральных спутниковых изображений, в котором реализованы разработанные автором методы и алгоритмы.
7. Разработан новый метод автоматического выделения водных объектов на мультиспектральных спутниковых изображениях высокого пространственного разрешения, основанный на использовании ансамблевого алгоритма кластеризации ЕССА. Разработанный метод реализован в программном комплексе «ЕССА-Pack», который внедрен в СЦ ФГБУ «НИЦ «Планета» (см. Приложение 4), где используется при создании оперативных карт паводковой обстановки по данным с отечественных космических аппаратов Ресурс-П и Канопус-В для потребителей Росгидромета и региональных служб МЧС.
8. Программный комплекс «ЕССА-Pack» внедрен в Центральном сибирском ботаническом саду СО РАН (см. Приложение 5), где используется для решения задач картографирования типов растительности по данным спутниковой съемки высокого пространственного разрешения.

Список литературы

1. Dey, V. A review on image segmentation techniques with remote sensing perspective / V. Dey, Y. Zhang, M. Zhong // Proc. ISPRS TC VII Symposium, IAPRS. – 2010. – Vol. 38. – Part 7A. – P. 31-42.
2. Дворкин, Б.А. Новейшие и перспективные спутники дистанционного зондирования Земли / Б.А. Дворкин, С.А. Дудкин // Геоматика. – 2013. – № 2. – С. 16-21.
3. Michel, J. Stable mean-shift algorithm and its application to the segmentation of arbitrarily large remote sensing images / J. Michel, D. Youssefi, M. Grizonnet // IEEE Transactions, Geoscience and Remote Sensing. – 2015. – Vol. 53. – No. 2. – P. 952-964.
4. Гонсалес, Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс // М.: Техносфера, 2005. – 1072 с.
5. Chauhan, A.S. Image segmentation methods: A survey approach/ A.S. Chauhan, S. Silakari, M. Dixit // Proc. Fourth International Conference on Communication Systems and Network Technologies. – IEEE, 2014. – P. 929-933.
6. Guarnieri, A. Automated techniques for satellite image segmentation / A. Guarnieri, A. Vettore // International archives of photogrammetry remote sensing and spatial information sciences. – 2002. – Vol. 34. – No. 4. – P. 406-410.
7. Шовенгердт, Р.А. Дистанционное зондирование. Методы и модели обработки изображений // М.: Техносфера, 2010. – 556 с.
8. Xie, Y. Remote sensing imagery in vegetation mapping: a review / Y. Xie, Z. Sha, M. Yu // Journal of plant ecology. – 2008. – Vol. 1. – No. 1. – P. 9-23.
9. Sarmah, S. A grid-density based technique for finding clusters in satellite image / S. Sarmah, D.K. Bhattacharyya // Pattern Recognition Letters. – 2012. – Vol. 33. – No. 5. – P. 589-604.
10. Schiwe, J. Segmentation of high-resolution remotely sensed data-concepts, applications and problems // International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences. – 2002. – Vol. 34. – No. 4. – P. 380-385.
11. Wang, A. Segmentation of multispectral high-resolution satellite imagery based on integrated feature distributions / A. Wang, S. Wang, A. Lucieer // International Journal of Remote Sensing. – 2010. – Vol. 31. – No. 6. – P. 1471-1483.

12. Zadkarami, M.R. Application of skew-normal in classification of satellite image / M.R. Zadkarami, M. Rowhani // Journal of Data Science. – 2010. – Vol. 8. – P. 597-606.
13. Tasdemir, K. An approximate spectral clustering ensemble for high spatial resolution remote-sensing images / K. Tasdemir, Y. Moazzen, I. Yildirim // IEEE Journal, Selected Topics in Applied Earth Observations and Remote Sensing. – 2015. – Vol. 8. – No. 5. – P. 1996-2004.
14. Барталев, С.А. Анализ возможностей применения методов сегментации спутниковых изображений для выявления изменений в лесах / С.А. Барталев, Т.С. Ховратович // Современные проблемы дистанционного зондирования Земли из космоса. – 2011. – Т. 8. – № 1. – С. 44-62.
15. Carleer, A.P. Assessment of very high spatial resolution satellite image segmentations / A.P. Carleer, O. Debeir, E. Wolff // Photogrammetric Engineering & Remote Sensing. – 2005. – Vol. 71. – No. 11. – P. 1285-1294.
16. Gagalowicz, A. Sequential synthesis of natural textures / A. Gagalowicz, S. De Ma // Computer Vision, Graphics and Image Processing. – 1985. – Vol. 30. – No. 3. – P. 289-315.
17. Кашкин, В.Б. Цифровая обработка аэрокосмических изображений: конспект лекций // Красноярск: ИПК СФУ. – 2008. – 121 с.
18. Deng, H. Unsupervised image segmentation using a simple MRF model with a new implementation scheme / H. Deng, D.A. Clausi // Pattern recognition. – 2004. – Vol. 37. – No. 12. – P. 2323-2335.
19. Chen, J. Image-object detectable in multiscale analysis on high-resolution remotely sensed imagery / J. Chen, D. Pan, Z. Mao // International Journal of Remote Sensing. – 2009. – Vol. 30. – No. 14. – P. 3585-3602.
20. Blaschke, T. Object based image analysis for remote sensing // ISPRS journal of photogrammetry and remote sensing. – 2010. – Vol. 65. – No. 1. – P. 2-16.
21. Хлебникова, Е.П. Исследование возможности использования цифровых снимков высокого разрешения для определения отражательных характеристик растительности / Е.П. Хлебникова, Д.П. Симонов // Интерэкспо Гео-Сибирь. – 2013. – Т. 1. – С. 64–69.
22. Кашкин, В.Б. Дистанционное зондирование Земли из космоса. Цифровая обработка изображений / В.Б. Кашкин, А.И. Сухинин // М.: Логос, 2001. – 264 с.

23. Arai, K. Image Clustering Method Based on Density Maps Derived from Self-Organizing Mapping: SOM // International Journal of Advanced Computer Science and Applications (IJACSA). – 2012. – Vol. 3. – No. 7. – P. 102-107.
24. Jain, A.K. Data clustering: 50 years beyond K-means // Pattern recognition letters. – 2010. – Vol. 31. – No. 8. – P. 651-666.
25. Xu, R. Survey of clustering algorithms / R. Xu, D. Wunsch // IEEE Transactions, Neural Networks. – 2005. – Vol. 16. – No. 3. – P. 645-678.
26. Jain, A.K. Data clustering: a review / A.K. Jain, M.N. Murty, P.J. Flynn // ACM computing surveys (CSUR). – 1999. – Vol. 31. – No. 3. – P. 264-323.
27. Filippone, M. A survey of kernel and spectral methods for clustering / M. Filippone, F. Camastra, F. Masulli, S. Rovetta // Pattern recognition. – 2008. – Vol. 41. – No. 1. – P. 176-190.
28. Fahad, A. A survey of clustering algorithms for big data: Taxonomy and empirical analysis / A. Fahad, N. Alshatri, Z. Tari et al. // IEEE Transactions, Emerging Topics in Computing. – 2014. – Vol. 2. – No. 3. – P. 267-279.
29. Ahmed, N. Recent review on image clustering // Image Processing, IET. – 2015. – Vol. 9. – No. 11. – P. 1020-1032.
30. Nagpal, A. Review based on data clustering algorithms / A. Nagpal, A. Jatain, D. Gaur // IEEE Conference, Information & Communication Technologies (ICT). – IEEE, 2013. – P. 298-303.
31. Arumugadevi, S. Comparison of clustering methods for segmenting color images / S. Arumugadevi, V. Seenivasagam // Indian Journal of Science and Technology. – 2015. – Vol. 8. – No. 7. – P. 670-677.
32. Kashef, R. Cooperative clustering / R. Kashef, M.S. Kamel // Pattern Recognition. – 2010. – Vol. 43. – No. 6. – P. 2315-2329.
33. Krstinic, D. Fast two-step histogram-based image segmentation / D. Krstinic, A.K. Skelin, I. Slapnicar // Image Processing, IET. – 2011. – Vol. 5. – No. 1. – P. 63-72.
34. Lloyd, S.P. Least squares quantization in PCM // IEEE Transactions, Information Theory. – 1982. – Vol. 28. – No. 2. – P. 129-137.
35. Bezdek, J.C. FCM: The fuzzy c-means clustering algorithm / J.C. Bezdek, R. Ehrlich, W. Full // Computers & Geosciences. – 1984. – Vol. 10. – No. 2. – P. 191-203.

36. Ball, G.H. A clustering technique for summarizing multivariate data / G.H. Ball, D.J. Hall // Behavioral science. – 1967. – Vol. 12. – No. 2. – P. 153-155.
37. Woo, K.G. FINDIT: a fast and intelligent subspace clustering algorithm using dimension voting / K.G. Woo, J.H. Lee, M.H. Kim, Y.J. Lee // Information and Software Technology. – 2004. – Vol. 46. – No. 4. – P. 255-271.
38. Елкин, Е.А. О возможности применения методов распознавания в палеонтологии / Е.А. Елкин, В.Н. Елкина, Н.Г. Загоруйко // Геология и геофизика. – 1967. – № 9. – С. 75-78.
39. Jalalat-Evakilkandi, M. A new hierarchical-clustering combination scheme based on scatter matrices and nearest neighbor criterion / M. Jalalat-Evakilkandi, A. Mirzaei // Proc. 5th International Symposium on Telecommunications (IST). – IEEE, 2010. – P. 904-908.
40. He, Y. A novel nonparametric clustering algorithm for discovering arbitrary shaped clusters / Y. He, L. Chen // Proc. Joint Conference of the Fourth International Conference on Information, Communications and Signal Processing and Fourth Pacific Rim Conference on Multimedia. – IEEE, 2003. – Vol. 3. – P. 1826-1830.
41. Lu, Y. PHA: A fast potential-based hierarchical agglomerative clustering method / Y. Lu, Y. Wan // Pattern Recognition. – 2013. – Vol. 46. – No. 5. – P. 1227-1239.
42. Sibson, R. SLINK: an optimally efficient algorithm for the single-link cluster method // The Computer Journal. – 1973. – Vol. 16. – No. 1. – P. 30-34.
43. Defays, D. An efficient algorithm for a complete link method // The Computer Journal. – 1977. – Vol. 20. – No. 4. – P. 364-366.
44. Hino, H. A nonparametric clustering algorithm with a quantile-based likelihood estimator / H. Hino, N. Murata // Neural computation. – 2014. – Vol. 26. – No. 9. – P. 2074-2101.
45. Karypis, G. Chameleon: Hierarchical clustering using dynamic modeling / G. Karypis, E.H. Han, V. Kumar // IEEE Computer. – 1999. – Vol. 32. – No. 8. – P. 68-75.
46. Zhang, T. BIRCH: an efficient data clustering method for very large databases / T. Zhang, R. Ramakrishnan, M. Livny // Proc. ACM SIGMOD international conference on Management of data. – ACM, 1996. – Vol. 25. – No. 2. – P. 103-114.
47. Guha, S. Cure: an efficient clustering algorithm for large databases / S. Guha, R. Rastogi, K. Shim // Information Systems. – 2001. – Vol. 26. – No. 1. – P. 35-58.

48. Guha, S. ROCK: A robust clustering algorithm for categorical attributes / S. Guha, R. Rastogi, K. Shim // Proc. 15th International Conference on Data Engineering, 1999. – IEEE, 1999. – P. 512-521.
49. Ankerst, M. OPTICS: ordering points to identify the clustering structure / M. Ankerst, M.M. Breunig, H.P. Kriegel, J. Sander // Proc. ACM SIGMOD international conference on Management of data. – ACM, 1999. – Vol. 28. – No. 2. – P. 49-60.
50. Achtert, E. DeLi-Clu: boosting robustness, completeness, usability, and efficiency of hierarchical clustering by a closest pair ranking / E. Achtert, C. Böhm, P. Kröger // Advances in Knowledge Discovery and Data Mining, LNCS. – Springer Berlin Heidelberg, 2006. – P. 119-128.
51. Vikjord, V. A new information theoretic clustering algorithm using K-NN / V. Vikjord, R. Jenssen // IEEE International Workshop, Machine Learning for Signal Processing (MLSP). – IEEE, 2013. – P. 1-6.
52. Пестунов, И.А. Алгоритмы кластеризации в задачах сегментации спутниковых изображений / И.А. Пестунов, Ю.Н. Синявский // Вестник Кемеровского государственного университета. – 2012. – Т. 4. – № 2. – С. 110–125.
53. Shang, F. Fast affinity propagation clustering: A multilevel approach / F. Shang, L.C. Jiao, J. Shi, F. Wang, M. Gong // Pattern recognition. – 2012. – Vol. 45. – No. 1. – P. 474-486.
54. Zhang, X. Local density adaptive similarity measurement for spectral clustering / X. Zhang, J. Li, H. Yu // Pattern Recognition Letters. – 2011. – Vol. 32. – No. 2. – P. 352-358.
55. Von Luxburg, U. A tutorial on spectral clustering // Statistics and computing. – 2007. – Vol. 17. – No. 4. – P. 395-416.
56. Jia, J. Soft spectral clustering ensemble applied to image segmentation / J. Jia, B. Liu, L. Jiao // Frontiers of Computer Science in China. – 2011. – Vol. 5. – No. 1. – P. 66-78.
57. Akbarizadeh, G. A new ensemble clustering method for PolSAR image segmentation / G. Akbarizadeh, M. Rahmani // Proc. 7th Conference on Information and Knowledge Technology (IKT). – IEEE, 2015. – P. 1-4.
58. Wang, Z. Spectral active clustering of remote sensing images / Z. Wang, G.S. Xia, C. Xiong, L. Zhang // Proc. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2014. – IEEE, 2014. – P. 1737-1740.

59. Kohonen, T. Self-Organizing Maps / T. Kohonen, M.R. Schroeder, T. S. Huang, S.O. Maps // (Third Extended Edition), New York, 2001. – 501 P.
60. Martinetz, T.M. 'Neural-gas' network for vector quantization and its application to time-series prediction / T.M. Martinetz, S.G. Berkovich, K.J. Schulten // IEEE Transactions on Neural Networks. – 1993. – Vol. 4. – No. 4. – P. 558-569.
61. Costa, J.A.F. Clustering of complex shaped data sets via Kohonen maps and mathematical morphology / J.A.F. Costa, Andrade Netto M. L. // Aerospace/Defense Sensing, Simulation, and Controls. – International Society for Optics and Photonics, 2001. – P. 16-27.
62. Dempster, A.P. Maximum Likelihood from Incomplete Data via the EM Algorithm / A.P. Dempster, N.M. Laird, D.B. Rubin // Journal of the Royal Statistical Society. Series B (Methodological). – 1977. – Vol. 39. – No. 1. – P. 1-38.
63. Деврой, Л. Непараметрическое оценивание плотности. L1-подход / Л. Деврой, Л. Дьерфи // М.: Мир, 1988. – 408 с.
64. Narendra, P.M. A non-parametric clustering scheme for LANDSAT / P.M. Narendra, M. Goldberg // Pattern Recognition. – 1977. – Vol. 9. – No. 4. – P. 207-215.
65. Al Aghbari, Z. Hill-manipulation: An effective algorithm for color image segmentation / Z. Al Aghbari, R. Al-Haj // Image and Vision Computing. – 2006. – Vol. 24. – No. 8. – P. 894-903.
66. Ester, M. A density-based algorithm for discovering clusters in large spatial databases with noise / M. Ester, H.P. Kriegel, J. Sander, X. Xu // Proc. Second International Conference on Knowledge Discovery and Data Mining (KDD-96). – AAAI Press, 1996. – Vol. 96. – No. 34. – P. 226-231.
67. Sander, J. Density-based clustering in spatial databases: The algorithm GDBSCAN and its applications / J. Sander, M. Ester, H.P. Kriegel, X. Xu // Data mining and knowledge discovery. – 1998. – Vol. 2. – No. 2. – P. 169-194.
68. Achtert, E. Mining hierarchies of correlation clusters / E. Achtert, C. Bohm, P. Kroger, A. Zimek // Proc. 18th International Conference on Scientific and Statistical Database Management (SSDBM). – IEEE, 2006. – P. 119-128.
69. Wimalawarne, K. Fast Nonparametric Image Segmentation with Dirichlet Processes // Proc. 4th International Conference on Information and Automation for Sustainability (ICIAFS). – IEEE, 2008. – P. 336-340.

70. Freedman, D. Fast mean shift by compact density representation / D. Freedman, P. Kisilev // Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – IEEE, 2009. – P. 1818-1825.
71. Cheng, Y. Mean shift, mode seeking, and clustering // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1995. – Vol. 17. – No. 8. – P. 790-799.
72. Fukunaga, K. The estimation of the gradient of a density function, with applications in pattern recognition / K. Fukunaga, L.D. Hostetler // IEEE Transactions on Information Theory. – 1975. – Vol. 21. – No. 1. – P. 32-40.
73. Hinneburg, A. An efficient approach to clustering in large multimedia databases with noise / A. Hinneburg, D.A. Keim // Proc. 4th International Conference Knowledge Discovery and Data Mining (KDD'98). – 1998. – Vol. 98. – P. 58-65.
74. Varga, B. High-resolution image segmentation using fully parallel mean shift / B. Varga, K. Karacs // EURASIP Journal on Advances in Signal Processing (JASP). – 2011. – Vol. 1. – No. 111. – P. 1-17.
75. Ilango, M.R. A Survey of Grid Based Clustering Algorithms / M.R. Ilango, V. Mohan // International Journal of Engineering Science and Technology. – 2010. – Vol. 2. – No. 8. – P. 3441-3446.
76. Aggarwal, C.C. Data clustering: algorithms and applications. / C.C. Aggarwal, C.K. Reddy // CRC Press, 2014. – 626 p.
77. Tsai, C.F. An effective and efficient grid-based data clustering algorithm using intuitive neighbor relationship for data mining / C.F. Tsai, S.C. Huang // Proc. International Conference on Machine Learning and Cybernetics (ICMLC). – IEEE, 2015. – Vol. 2. – P. 478-483.
78. Tsai, C.F. Enhancement of efficiency by thrifty search of interlocking neighbor grids approach for grid-based data clustering / C.F. Tsai, Y.C. Hu // Proc. International Conference on Machine Learning and Cybernetics (ICMLC). – IEEE, 2013. – Vol. 3. – P. 1279-1284.
79. Tsai, C.F. Grid Clustering Algorithm with Simple Leaping Search Technique / C.F. Tsai, J.H. Zhang // Proc. International Symposium on Computer, Consumer and Control (IS3C). – IEEE, 2012. – P. 938-941.

80. Agrawal, R. Automatic subspace clustering of high dimensional data for data mining applications / R. Agrawal, J. Gehrke, D. Gunopulos, P. Raghavan // Proc. ACM SIGMOD International Conference on Management of Data – ACM, 1998. – Vol. 27. – No. 2. – P. 94-105.
81. Sheikholeslami, G. Wavecluster: A multi-resolution clustering approach for very large spatial databases / G. Sheikholeslami, S. Chatterjee, A. Zhang // Proc. 24th International Conference on Very Large Data Bases (VLDB). – 1998. – P. 428-439.
82. Dou, W. A half-split grid clustering algorithm by simulating cell division / W. Dou, J. Hu // Proc. International Joint Conference on Neural Networks (IJCNN). – IEEE, 2014. – P. 2183-2189.
83. Esfandani, G. GDCLU: a new Grid-Density based CLUstring algorithm / G. Esfandani, M. Sayyadi, A. Namadchian // Proc. 13th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel & Distributed Computing (SNPD). – IEEE, 2012. – P. 102-107.
84. Zhuo, C. A fast clustering algorithm based on grid and density condensation point / C. Zhuo, M. Qingchun, W. Zhengang, R. Li-Jie, D. Jin-Feng // Journal of Harbin Institute of Technology. – 2005. – Vol. 37. – No. 12. – P. 1654-1657.
85. Zhuo, C. A Fast Incremental Clustering Algorithm Based on Grid and Density / C. Zhuo, L. Xiang-Shuang, Z. Xiao-Dong // Proc. Third International Conference on Natural Computation (ICNC). – IEEE, 2007. – Vol. 5. – P. 207-211.
86. Schikuta, E. Grid-Clustering: A Hierarchical Clustering Method for Very Large Data Sets // Proc. 13th International Conference on Pattern Recognition. – 1993. – Vol. 2. – P. 101-105.
87. Chang, C.I. An Axis-Shifted Grid-Clustering Algorithm / C.I. Chang, N.P. Lin, N.Y. Jan // Tamkang Journal of Science and Engineering. – 2009. – Vol. 12. – No. 2. – P. 183-192.
88. Lin, N.P. A deflected grid-based algorithm for clustering analysis / N.P. Lin, C.I. Chang, H.E. Chueh, H.J. Chen, W.H. Hao // WSEAS Transactions on Computers. – 2008. – Vol. 7. – No. 4. – P. 125-132.
89. Ma, E. A new shifting grid clustering algorithm / E. Ma, T. Chow // Pattern Recognition. – 2004. – Vol. 37. – No. 3. – P. 503-514.

90. Liao, W. A grid-based clustering algorithm using adaptive mesh refinement / W. Liao, Y. Liu, A. Choudhary // 7th Workshop on Mining Scientific and Engineering Datasets of SIAM International Conference on Data Mining. – 2004. – P. 61-69.
91. Szkudlarek, M. Fast grid-based clustering method for automatic calculation of optimal parameters of skin color classifier for head tracking / M. Szkudlarek, M. Pietruszka // Proc. IEEE 2nd International Conference on Cybernetics (CYBCONF). – IEEE, 2015. – P. 119-124.
92. Barbará, D. Using the fractal dimension to cluster datasets / D. Barbará, P. Chen // Proc. 6th ACM international conference on Knowledge discovery and data mining (SIGKDD). – ACM, 2000. – P. 260-264.
93. Wang, W. STING: A statistical information grid approach to spatial data mining / W. Wang, J. Yang, M. Muntz // Proc. Int. Conf. on Very Large Data Bases (VLDB). – 1997. – P. 186-195.
94. Nagesh, H.S. Adaptive Grids for Clustering Massive Data Sets / H.S. Nagesh, S. Goil, A.N. Choudhary // Proc. 1st SIAM International Conference on Data Mining (SDM). – 2001. – P. 1-17.
95. Hinneburg, A. Optimal grid-clustering: Towards breaking the curse of dimensionality in high-dimensional clustering / A. Hinneburg, D.A. Keim // Proc. 25th International Conference on Very Large Databases (VLDB). – 1999. – P. 506-517.
96. Akodjènou-Jeannin, M.I. Flexible grid-based clustering / M.I. Akodjènou-Jeannin, K. Salamatian, P. Gallinari // Proc. Knowledge Discovery in Databases: PKDD 2007. – Springer, 2007. – P. 350-357.
97. Zhao, Z. A novel method for image clustering / Z. Zhao, Q. Ma // Proc. 10th International Conference on Natural Computation (ICNC). – IEEE, 2014. – P. 648-652.
98. Ghaemi, R. A survey: clustering ensembles techniques / R. Ghaemi, M.N. Sulaiman, H. Ibrahim, N. Mustapha // International Journal of Computer, Electrical, Automation, Control and Information Engineering – 2009. – Vol. 3. – No. 2. – P. 365-374.
99. Hore, P. A scalable framework for cluster ensembles / P. Hore, L.O. Hall, D.B. Goldgof // Pattern Recognition. – 2009. – Vol. 42. – No. 5. – P. 676-688.
100. Franek, L. Ensemble clustering by means of clustering embedding in vector spaces / L. Franek, X. Jiang // Pattern Recognition. – 2014. – Vol. 47. – No. 2. – P. 833-842.

101. Zhang, S. Unsupervised evaluation of cluster ensemble solutions / S. Zhang, L. Yang, D. Xie // Proc. 7th International Conference on Advanced Computational Intelligence (ICACI). – IEEE, 2015. – P. 101-106.
102. Strehl, A. Cluster ensembles—a knowledge reuse framework for combining multiple partitions / A. Strehl, J. Ghosh // The Journal of Machine Learning Research. – 2003. – Vol. 3. – P. 583-617.
103. Бериков, В.Б. Построение ансамбля деревьев решений в кластерном анализе // Вычислительные технологии. – 2010. – Т. 15. – № 1. – С. 40-52.
104. Hore, P. A cluster ensemble framework for large data sets / P. Hore, L. Hall, D. Goldgof // IEEE International Conference on Systems, Man and Cybernetics. – IEEE, 2006. – Vol. 4. – P. 3342-3347.
105. Filkov, V. Integrating microarray data by consensus clustering / V. Filkov, S. Skiena // International Journal on Artificial Intelligence Tools. – 2004. – Vol. 13. – No. 04. – P. 863-880.
106. Ilea, D.E. Image segmentation based on the integration of colour–texture descriptors – A review / D.E. Ilea, P.F. Whelan // Pattern Recognition. – 2011. – Vol. 44. – No. 10. – P. 2479-2501.
107. Deng, Y. Unsupervised segmentation of color-texture regions in images and video / Y. Deng, B.S. Manjunath // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2001. – Vol. 23. – No. 8. – P. 800-810.
108. Wang, Y. Unsupervised color–texture segmentation based on soft criterion with adaptive mean-shift clustering / Y. Wang, J. Yang, N. Peng // Pattern Recognition Letters. – 2006. – Vol. 27. – No. 5. – P. 386-392.
109. Zhang, J. Image segmentation with texture clustering based JSEG / J. Zhang, Y.W. Gao, S.W. Feng, Z.H. Chen, Y.B. Yuan // Proc. International Conference on Machine Learning and Cybernetics (ICMLC). – IEEE, 2015. – Vol. 2. – P. 599-603.
110. Mignotte, M. A de-texturing and spatially constrained K-means approach for image segmentation // Pattern Recognition Letters. – 2011. – Vol. 32. – No. 2. – P. 359-367.
111. Ilea, D.E. Color image segmentation using a self-initializing EM algorithm. / D.E. Ilea, P.F. Whelan // Proc. 6th International Conference Visualization, Imaging, Image Processing (IASTED). – 2006. – P. 417-424.

112. Nammalwar, P. Integration of feature distributions for colour texture segmentation / P. Nammalwar, O. Ghita, P.F. Whelan // Proc. 17th International Conference on Pattern Recognition (ICPR). – IEEE, 2004. – Vol. 1. – P. 716-719.
113. Sima, H. Texture Region Merging with Histogram Feature for Color Image Segmentation / H. Sima, P. Guo // Proc. 9th International Conference on Computational Intelligence and Security (CIS). – IEEE, 2013. – P. 224-228.
114. Hu, X. Automatic segmentation of high-resolution satellite imagery by integrating texture, intensity, and color features / X. Hu, C.V. Tao, B. Prenzel // Photogrammetric Engineering & Remote Sensing. – 2005. – Vol. 71. – No. 12. – P. 1399-1406.
115. Wang, A. Segmentation of multispectral high-resolution satellite imagery based on integrated feature distributions / A. Wang, S. Wang, A. Lucieer // International Journal of Remote Sensing. – 2010. – Vol. 31. – No. 6. – P. 1471-1483.
116. Wuest, B. Region Based Segmentation of Quickbird Imagery Through Fuzzy Integration / B. Wuest, Y. Zhang // Proc. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (IAPRS). – 2008. – Vol. 37, part B7. – P. 491-496.
117. Hu, Z. A spatially-constrained color–texture model for hierarchical VHR image segmentation / Z. Hu, Z. Wu, Q. Zhang, Q. Fan, J. Xu // Geoscience and Remote Sensing Letters, IEEE. – 2013. – Vol. 10. – No. 1. – P. 120-124.
118. Yang, Y. Multilayer graph cuts based unsupervised color–texture image segmentation using multivariate mixed student's t-distribution and regional credibility merging / Y. Yang, S. Han, T. Wang, W. Tao, X.C. Tai // Pattern Recognition. – 2013. – Vol. 46. – No. 4. – P. 1101-1124.
119. Ilea, D.E. CTex – an adaptive unsupervised segmentation algorithm based on color–texture coherence / D.E. Ilea, P.F. Whelan // IEEE Transactions on Image Processing. – 2008. – Vol. 17. – No. 10. – P. 1926-1939.
120. Yuan, J. Remote sensing image segmentation by combining spectral and texture features / J. Yuan, D.L. Wang, R. Li // IEEE Transactions on Geoscience and Remote Sensing. – 2014. – Vol. 52. – No. 1. – P. 16-24.
121. Senturk, S. Unsupervised classification of vineyard parcels using SPOT5 images by utilizing spectral and textural features / S. Senturk, K. Taşdemir, S. Kaya, E. Sertel // Proc. 2nd International Conference on Agro-Geoinformatics. – IEEE, 2013. – P. 61-65.

122. Duin, R.P.W. et al. A Matlab Toolbox for Pattern Recognition. [Электронный ресурс]. – URL: <http://www.prtools.org> (дата обращения: 12.05.2016).
123. Пестунов, И.А. Ансамблевый алгоритм кластеризации больших массивов данных / И.А. Пестунов, В.Б. Бериков, Е.А. Куликова, С.А. Рылов // Автометрия. – 2011. – Т. 47. – № 3. – С. 49-58.
124. Кендал, М. Многомерный статистический анализ и временные ряды / М. Кендал, А. Стьюарт // М.: Наука, 1976. – С. 441-443.
125. Leclerc, B. Description combinatoire des ultramétries // Mathématiques et Sciences humaines. – 1981. – Vol. 73. – P. 5-37.
126. Mirzaei, A. A novel hierarchical-clustering-combination scheme based on fuzzy-similarity relations / A. Mirzaei, M. Rahmati // IEEE Transactions on Fuzzy Systems. – 2010. – Vol. 18. – No. 1. – P. 27-39.
127. Zheng, L. Hierarchical ensemble clustering / L. Zheng, T. Li, C. Ding // Proc. IEEE 10th International Conference on Data Mining (ICDM). – IEEE, 2010. – P. 1199-1204.
128. Skiena, S.S. The Algorithm Design Manual // Springer, 2nd ed, 2008. – 730 p.
129. Olson, C.F. Parallel algorithms for hierarchical clustering // Parallel computing. – 1995. – Vol. 21. – No. 8. – P. 1313-1325.
130. Achtert, E. Interactive data mining with 3D-parallel-coordinate-trees / E. Achtert, H.P. Kriegel, E. Schubert, A. Zimek // Proc. ACM International Conference on Management of Data (SIGMOD). – ACM, 2013. – P. 1009-1012.
131. Rashedi, E. A hierarchical clusterer ensemble method based on boosting theory / E. Rashedi, A. Mirzaei // Knowledge-Based Systems. – 2013. – Vol. 45. – P. 83-93.
132. Vichi, M. Principal classifications analysis: a method for generating consensus dendrograms and its application to three-way data // Computational statistics & data analysis. – 1998. – Vol. 27. – No. 3. – P. 311-331.
133. Рылов, С.А. Тестовые данные для кластеризации [Электронный ресурс]. Электронные данные (10 текстовых файлов и 11 файлов изображений). – 2016. – URL: <https://drive.google.com/folderview?id=0ByK9GtU5ExExWXpGRjU5WVfHcDg> (дата обращения: 11.07.2016).
134. Junior, J.J.M. Color texture classification based on gravitational collapse / J.J.M. Junior, A.R. Backes, P.C. Cortez // Pattern Recognition. – 2013. – Vol. 46. – No. 6. – P. 1628-1637.

135. Song, Y. Building extraction from high resolution color imagery based on edge flow driven active contour and JSEG / Y. Song, J. Shan // IAPRSIS. – 2008. – Vol. 37. – P. 185-190.
136. McFeeters, S.K. Using the Normalized Difference Water Index (NDWI) within a geographic information system to detect swimming pools for mosquito abatement: a practical approach // Remote Sensing. – 2013. – Vol. 5. – No. 7. – P. 3544-3561.
137. Пестунов, И.А. Выделение объектов неприродного происхождения на спутниковых снимках высокого разрешения с использованием фильтра Кэнни / И.А. Пестунов, Д.В. Лазарев, Ю.Н. Синявский // Сборник трудов Всероссийской конференции «Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов (SDM–2015)». – Новосибирск, 2015. – С. 115–119.
138. Пестунов, И.А. Метод выделения теней на мультиспектральных спутниковых изображениях высокого пространственного разрешения / И.А. Пестунов, С.А. Рылов // Материалы молодежной школы-семинара «Дистанционное зондирование Земли из космоса: алгоритмы, технологии, данные». – Барнаул: АЗБУКА, 2013. – С. 60-73.
139. GDAL – Geospatial Data Abstraction Library [Электронный ресурс]. – URL: <http://www.gdal.org/> (дата обращения 13.05.2016).
140. Рылов, С.А. Руководство пользователя программы «ЕССА–Pack» [Электронный ресурс]. Электронные данные (1 текстовый файл, pdf). – 2015. – URL: <https://drive.google.com/open?id=0ByK9GtU5ExExX1RYRS1NUVVnZWws> (дата обращения: 13.05.2016).
141. Sun, F. Comparison and improvement of methods for identifying waterbodies in remotely sensed imagery / F. Sun, W. Sun, J. Chen, P. Gong // International Journal of Remote Sensing. – 2012. – Vol. 33. – No. 21. – P. 6854-6875.
142. Gedik, E. A new robust method for bridge detection from high resolution electro-optic satellite images / E. Gedik, U. Cinar, E. Karaman, Y. Yardimci, U. Halici, K. Pakin // Proc. 4th GEOBIA. – 2012. – P. 298-302.
143. Purba, G.S. Identification of flood affected areas-need for a scientific approach / G.S. Purba, B. Chakravorty, M. Kumar // Proc. Indian Disaster Management Congress. – 2006. – Vol. 30. – P. 1-11.

144. Антонов, В.Н. Мониторинг и картографирование паводковой ситуации в сибирском федеральном округе / В.Н. Антонов, О.Г. Новгородцева // Образовательные ресурсы и технологии. – 2014. – № 8. – С. 81-86.
145. Sivanpillai, R. Improvements in mapping water bodies using ASTER data / R. Sivanpillai, S.N. Miller // Ecological Informatics. – 2010. – Vol. 5. – No. 1. – P. 73-78.
146. Ермаков, Н.Б. Картографическое моделирование пространственной организации растительного покрова / Н.Б. Ермаков, К.С. Алсынбаев, Д.Ю. Попов, Я.С. Суляев // Биоразнообразие и динамика экосистем: информационные технологии и моделирование // Новосибирск: Издательство СО РАН, 2006. – С. 276-288.
147. Корчагин, А.А. Полевая геоботаника. Методическое руководство. // М.: Издательство АН СССР, 1964. – Т. 3. – 530 с.
148. Hennekens, S.M. TURBO(VEG). Software package for input, processing and presentation of phytosociological data. User's guide. // Lancaster: IBN-DLO, 1996. University of Lancaster. – 59 p.
149. Westhoff, V. The Braun-Blanquet approach. / V. Westhoff, E. Van Der Maarel / In: Whittaker, R.H. (ed.) // Handbook of vegetation science. Part 5: Classification and ordination of communities. Junk, The Hague, 1973. – P. 617-726.
150. Hill, M.O. DECORANA and TWINSpan, for Ordination and Classification of Multivariate Species Data: A New Edition, Together with Supporting Programs, in FORTRAN 77 // Huntington: Institute of Terrestrial Ecology, 1979. – 58 p.
151. The benefits of the eight spectral bands of WorldView-2 [Электронный ресурс]. – 2010. – URL: http://www.digitalglobe.com/sites/default/files/DG-8SPECTRAL-WP_0.pdf (дата обращения 13.05.2016).

Публикации автора по теме диссертационной работы

В рецензируемых журналах, рекомендованных ВАК:

1. Пестунов, И.А. Ансамблевый алгоритм кластеризации больших массивов данных / И.А. Пестунов, В.Б. Бериков, Е.А. Куликова, С.А. Рылов // Автометрия. – 2011. – Т. 47. – № 3. – С. 49-58.

[Англ. версия] Pestunov, I.A. Ensemble of clustering algorithms for large datasets / I.A. Pestunov, V.B. Berikov, E.A. Kulikova, S.A. Rylov // Optoelectronics, instrumentation and data processing. – 2011. – Vol. 47. – No. 3. – P. 245-252.

2. Пестунов, И.А. Алгоритмы спектрально-текстурной сегментации спутниковых изображений высокого пространственного разрешения / И.А. Пестунов, С.А. Рылов // Вестник Кемеровского государственного университета. – 2012. – Т. 52. – № 4/2 (52). – С. 104-110.

3. Пестунов, И.А. Иерархические алгоритмы кластеризации для сегментации мультиспектральных изображений / И.А. Пестунов, С.А. Рылов, В.Б. Бериков // Автометрия. – 2015. – Т. 51. – № 4. – С. 12-22.

[Англ. версия] Pestunov, I.A. Hierarchical clustering algorithms for segmentation of multispectral images / I.A. Pestunov, S.A. Rylov, V.B. Berikov // Optoelectronics, instrumentation and data processing. – 2015. – Vol. 51. – No. 4. – P. 329-338.

4. Синявский, Ю.Н. Методы и технология сегментации мультиспектральных изображений высокого разрешения для исследования природных и антропогенных объектов / Ю.Н. Синявский, И.А. Пестунов, О.А. Дубровская, С.А. Рылов, П.В. Мельников, Н.Б. Ермаков, М.А. Полякова // Вычислительные технологии. – 2016. – Т. 21. – № 1. – С. 127-140.

В других рецензируемых изданиях:

5. Пестунов, И.А. Сегментация изображений на основе кластеризации в пространстве спектральных и текстурных признаков / И.А. Пестунов, С.А. Рылов // Известия Кыргызского государственного технического университета им. И. Раззакова. Материалы международной конференции «Информационные технологии и математическое моделирование в науке, технике и образовании». – 2011. – № 24. – С. 266-270.


6. Пестунов, И.А. Сегментация спутниковых изображений высокого разрешения по спектральным и текстурным признакам / И.А. Пестунов, С.А. Рылов // Интерэкспо ГЕО-Сибирь. – 2012. – Т. 1. – № 4. – С. 86-91.
7. Пестунов, И.А. Технология и программный инструментарий для сегментации спутниковых изображений высокого пространственного разрешения / И.А. Пестунов, С.А. Рылов, П.В. Мельников, Ю.Н. Сиявский // Интерэкспо ГЕО-Сибирь. – 2013. – Т. 4. – № 1. – С. 202-208.
8. Рылов, С.А. Использование графических процессоров NVIDIA при кластеризации мультиспектральных данных сеточным алгоритмом ССА / С.А. Рылов, И.А. Пестунов // Интерэкспо ГЕО-Сибирь. – 2015. – Т. 4. – № 2. – С. 51-56.
9. Сиявский, Ю.Н. Совместная обработка разнородных данных при сегментации спутниковых изображений высокого разрешения / Ю.Н. Сиявский, И.А. Пестунов, С.А. Рылов, П.В. Мельников // Интерэкспо ГЕО-Сибирь. – 2015. – Т. 4. – № 2. – С. 57-61.
10. Рылов, С.А. Спектрально-текстурная классификация гиперспектральных изображений высокого пространственного разрешения / С.А. Рылов, П.В. Мельников, И.А. Пестунов // Интерэкспо ГЕО-Сибирь. – 2016. – Т. 4. – № 1. – С. 78-84.

В трудах международных и всероссийских конференций:

11. Пестунов, И.А. Спектрально-текстурная сегментация спутниковых изображений высокого пространственного разрешения / И.А. Пестунов, С.А. Рылов // Сборник трудов XI Всероссийской конференции с участием иностранных ученых «Проблемы мониторинга окружающей среды» (ЕМ-2011). – Кемерово: КемГУ, 2011. – С. 357-361.
12. Харук, В.И. Обнаружение и классификация усыхающих кедровых древостоев по спутниковым данным высокого пространственного разрешения / В.И. Харук, И.А. Пестунов, О.А. Дубровская, П.В. Мельников, С.А. Рылов // Сборник материалов Международной конференции и школы молодых ученых по измерениям, моделированию и информационным системам для изучения окружающей среды «ENVIROMIS-2014». – Томск: Томский ЦНТИ, 2014. – С. 178-180.
13. Ермаков, Н.Б. Крупномасштабное картографирование структуры степной растительности и выявление сообществ с редкими и уникальными видами растений на территории Южной Сибири с использованием снимков высокого разрешения /

- Н.Б. Ермаков, И.А. Пестунов, М.А. Полякова, О.А. Дубровская, С.А. Рылов, Ю.Н. Синявский // Материалы международной научной конференции «Региональные проблемы дистанционного зондирования Земли». – Красноярск: СФУ, 2014. – С. 224-229.
14. Пестунов, И.А. Метод построения ансамбля сеточных иерархических алгоритмов кластеризации для сегментации спутниковых изображений / И.А. Пестунов, С.А. Рылов // Материалы международной научной конференции «Региональные проблемы дистанционного зондирования Земли». – Красноярск: СФУ, 2014. – С. 215-223.
 15. Pestunov, I. Hierarchical Ensemble Clustering Algorithm for Multispectral Image Segmentation / I. Pestunov, S. Rylov, V. Berikov // Proceedings 9th Open German-Russian Workshop on Pattern Recognition and Image Understanding (OGRW-2014). – Koblenz: University of Koblenz-Landau, 2015. – P. 123-127.
 16. Рылов, С.А. Иерархические алгоритмы кластеризации мультиспектральных изображений и их использование при создании тематических карт паводковой обстановки / С.А. Рылов, О.Г. Новгородцева, О.А. Дубровская, И.А. Пестунов // Сборник трудов Всероссийской конференции «Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов (SDM – 2015)». – Новосибирск, 2015. – С. 165-171.
 17. Рылов, С.А. Технология обработки данных с космических аппаратов «Канопус-В», «Песурс-П» и «Метеор-М» для мониторинга и картографирования паводковой ситуации / С.А. Рылов, О.Г. Новгородцева, И.А. Пестунов, О.А. Дубровская, Ю.Н. Синявский // Материалы II Международной научной конференции «Региональные проблемы дистанционного зондирования Земли». – Красноярск: СФУ, 2015. – С. 207-212.
 18. Рылов, С.А. Мониторинг паводковой ситуации по спутниковым изображениям высокого разрешения с учетом наличия теней / С.А. Рылов, О.Г. Новгородцева, И.А. Пестунов // Материалы 6-ой Международной научно-практической конференции. «АГРОИНФО-2015». Ч. 1: Информационные технологии, системы и приборы в АПК. – Новосибирск, 2015. – С. 434-439.

Приложение 1. Свидетельство о государственной регистрации программы «ЕССА»

РОССИЙСКАЯ ФЕДЕРАЦИЯ	
	
ДУБЛИКАТ	
СВИДЕТЕЛЬСТВО	
о государственной регистрации программы для ЭВМ	
№ 2011610996	
ЕССА/10	
Правообладатель(ли): <i>Учреждение Российской академии наук Институт вычислительных технологий Сибирского отделения РАН (RU)</i>	
Автор(ы): <i>Пестунов Игорь Алексеевич, Куликова Екатерина Александровна, Рылов Сергей Александрович (RU)</i>	
	Заявка № 2010617608
	Дата поступления 2 декабря 2010 г.
	Зарегистрировано в Реестре программ для ЭВМ 27 января 2011 г.
Руководитель Федеральной службы по интеллектуальной собственности, патентам и товарным знакам	
 Б.П. Симонов	

Приложение 2. Свидетельство о государственной регистрации программы «ESEG»

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО
о государственной регистрации программы для ЭВМ
№ 2013611866
ESEG


Правообладатель(ли): **Федеральное государственное бюджетное учреждение науки Институт вычислительных технологий Сибирского отделения Российской академии наук (RU)**

Автор(ы): **Пестунов Игорь Алексеевич (RU),
Рылов Сергей Александрович (RU)**

Заявка № **2012661387**
Дата поступления **19 декабря 2012 г.**
Зарегистрировано в Реестре программ для ЭВМ
07 февраля 2013 г.



Руководитель Федеральной службы
по интеллектуальной собственности



Б.П. Симонов

Приложение 3. Свидетельство о государственной регистрации программы «ShadowExtractor»

РОССИЙСКАЯ ФЕДЕРАЦИЯ	
	
СВИДЕТЕЛЬСТВО	
о государственной регистрации программы для ЭВМ	
№ 2016610256	
ShadowExtractor	
Правообладатель: <i>Федеральное государственное бюджетное учреждение науки Институт вычислительных технологий Сибирского отделения Российской академии наук (RU)</i>	
Авторы: <i>Пестунов Игорь Алексеевич (RU), Рылов Сергей Александрович (RU)</i>	
	Заявка № 2015660972
	Дата поступления 13 ноября 2015 г.
	Дата государственной регистрации в Реестре программ для ЭВМ 11 января 2016 г.
	Руководитель Федеральной службы по интеллектуальной собственности  Г.П. Ивлиев

Приложение 4. Акт внедрения результатов в Сибирском центре ФГБУ «НИЦ «Планета»

Росгидромет

Федеральное государственное бюджетное
учреждение
«Научно-исследовательский центр
космической гидрометеорологии «Планета»
СИБИРСКИЙ ЦЕНТР
(СЦ ФГБУ «НИЦ «ПЛАНЕТА»)

630099, г. Новосибирск, ул. Советская, 30,
Тел./факс(383) 222-33-07, 334-45-42
E-mail: avn@rcpod.ru

УТВЕРЖДАЮ

Директор
СЦ ФГБУ «НИЦ «Планета»
В.Н. Антонов

« »

2016 г.



АКТ

о внедрении результатов исследований

Настоящим Актом подтверждается, что результаты исследований Рылова Сергея Александровича, изложенные в диссертации на соискание учёной степени кандидата технических наук «Методы и алгоритмы сегментации мультиспектральных спутниковых изображений высокого пространственного разрешения», используются в отделе обработки спутниковой информации Сибирского Центра ФГБУ "НИЦ "Планета". Реализованные в виде программного приложения методы и алгоритмы сегментации мультиспектральных изображений позволяют решать задачу мониторинга паводковой ситуации путем выделения водной поверхности на спутниковом изображении. Результаты классификации являются основой при составлении тематических карт паводковой обстановки по данным КА «Канопус-В», «Метеор-М» №1, №2 и «Ресурс-П» №1, №2, №3 в оперативном режиме.

Заместитель директора
СЦ ФГБУ «НИЦ «Планета»

Заведующая отделом ОСИ
СЦ ФГБУ «НИЦ «Планета»

И. А. Соловьева

О. Г. Новикова

27.02.2015

Приложение 5. Акт внедрения результатов в Центральном сибирском ботаническом саду СО РАН

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
УЧРЕЖДЕНИЕ НАУКИ

**ЦЕНТРАЛЬНЫЙ СИБИРСКИЙ
БОТАНИЧЕСКИЙ САД
СИБИРСКОГО ОТДЕЛЕНИЯ
РОССИЙСКОЙ АКАДЕМИИ НАУК
(ЦСБС СО РАН)**

ул. Золотодолинская, д. 101, Новосибирск, 630090
Для телеграмм: Новосибирск – 90, «Ботсад»
Факс (383) 330-19-86
Телефон (383) 330-41-01
E-mail: botgard@ngs.ru
http://www.csbg.nsc.ru



УТВЕРЖДАЮ

Директор ЦСБС СО РАН

Банаев Е.В.

» _____ 2016 г.

16.05.2016 № 15344-01/21.9317

На № _____ от _____

АКТ

о внедрении результатов исследований

Настоящим Актом подтверждается, что результаты исследований Рылова Сергея Александровича, изложенные в диссертации на соискание учёной степени кандидата технических наук «Методы и алгоритмы сегментация мультиспектральных спутниковых изображений высокого пространственного разрешения», использованы сотрудниками Центрального Сибирского ботанического сада СО РАН при исследовании территории Южной Сибири. Разработанные алгоритмы и программное обеспечение позволили выполнить крупномасштабное моделирование пространственной организации степной растительности с целью выявления важных закономерностей формирования растительного покрова горно-степного пояса и обнаружения сообществ, включающих редкие и уникальные виды растений, а также построить детальные карты растительности исследуемых регионов.

Главный научный сотрудник
ЦСБС СО РАН, д.б.н.

Н.Б. Ермаков