

Федеральное агентство научных организаций России
Федеральное государственное бюджетное учреждение науки
Физико-технический институт
Уральского отделения Российской Академии наук



На правах рукописи

Назмутдинова Айгуль Илсуровна

**РАЗРАБОТКА И ИССЛЕДОВАНИЕ МЕТОДА ИНТЕПРЕТАЦИИ
КОСМИЧЕСКИХ СНИМКОВ ПЛОЩАДНЫХ ОБЪЕКТОВ МЕСТНОСТИ
НА ОСНОВЕ ВЕЙВЛЕТ-АНАЛИЗА**

Специальность 05.13.01 - Системный анализ, управление и обработка
информации (в науке и технике)

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель:
к.т.н., старший научный
сотрудник Милич В.Н.

ОГЛАВЛЕНИЕ

Введение	5
Глава 1. Модели и методы обработки данных дистанционного зондирования	16
1.1. Данные дистанционного зондирования Земли	16
1.2. Задача интерпретации изображений площадных объектов местности по данным дистанционного зондирования	22
1.3. Методы и алгоритмы анализа данных дистанционного зондирования	27
1.4. Методы классификации и методы оценки точности	35
1.5. Сравнительный анализ известных реализаций систем интерпретации изображений площадных объектов местности	44
1.6. Выводы по Главе 1	46
Глава 2. Метод интерпретации данных дистанционного зондирования в задаче классификации лесной растительности	48
2.1. Системный анализ задачи интерпретации космических снимков площадных объектов местности.....	48
2.2. Вейвлет-преобразование как основа определения признаков изображения.....	56
2.3. Метод принятия обоснованного решения о классе распознаваемого объекта.....	68
2.4. Алгоритмические и методические основы выбора информативных признаков.....	75
2.5. Выводы по Главе 2	79

Глава 3. Система признаков мультиспектральных данных для их интерпретации	81
3.1. Базовая система признаков.....	81
3.2. Базовая система признаков, дополненная характеристиками бинарного представления изображений ДВП	89
3.3. Исследование эффективности и устойчивости признаков	93
3.4. Выводы по Главе 3	98
Глава 4. Вопросы реализации разработанного метода.....	99
4.1. Средства реализации и программные средства	99
4.2. Классификация объектов растительности по данным съемочной системы QuickBird	101
4.3. Классификация объектов лесной растительности по данным съемочной системы RapidEye.....	105
4.4. Классификация объектов растительности по изображениям, полученным с низколетящего беспилотного летательного аппарата	113
4.5. Использование мультиспектральных данных высокого пространственного разрешения для обнаружения областей местности с характерными свойствами.	115
4.6. Выводы по Главе 4	121
Заключение.....	122
Список сокращений и условных обозначений	124
Список литературы.....	125
Приложение А. Характеристики известных реализаций систем интерпретации изображений площадных объектов местности	141

Приложение Б. Текст программы «Программное обеспечение определения разновидностей объектов растительности по их многозональным изображениям».....	147
Приложение С. Копия свидетельства о регистрации программы	158

Введение

Актуальность. Рациональное природопользование является в соответствии с Указом Президента Российской Федерации от 7 июля 2011 г. № 899 одним из приоритетных направлений развития науки, технологий и техники в Российской Федерации. Кроме того, в перечне технологий (утверждено распоряжением правительства РФ с изменениями от 14.06.2013), имеющих важное социально-экономическое значение или важное значение для обороны страны и безопасности государства (критических технологий), значатся:

- технологии мониторинга и прогнозирования состояния окружающей среды, предотвращения и ликвидации ее загрязнения (п. 14);
- технологии предупреждения и ликвидации чрезвычайных ситуаций природного и техногенного характера (п. 22).

Решение задач развития указанного приоритетного направления и перечисленных критических технологий невозможно без разработки новых эффективных методов оценки характеристик и состояния природных объектов. Наиболее массовыми объектами территории являются площадные объекты растительных покровов и грунтов. Эти объекты (леса, поля, пустынные территории и пр.) являются, с одной стороны, одним из основных природных ресурсов России, а с другой стороны, они наиболее трудны для оценки их состояния ввиду значительного разнообразия и огромных площадей. Именно для таких объектов очень важно проводить мониторинг состояния и оценку ресурсов, в том числе потому, что они являются индикаторами различных процессов загрязнения и чрезвычайных ситуаций.

По некоторым данным общая площадь лесов на территории Российской Федерации составляет примерно 8,5 млн. кв. км [103]. Оценка характеристик и состояния таких больших площадей является трудоемкой задачей, которую невозможно решить традиционными наземными методами. Поэтому одним из основных средств исследования природных ресурсов, позволяющим обеспечить рациональное природопользование, является дистанционное зондирование Земли

(ДЗЗ). Современные мультиспектральные данные высокого разрешения способны охватывать большие территории и отображать отличительные особенности лесов. Такими особенностями являются видовой состав, возраст, лесотаксационные характеристики, состояние, характеризующее экологическую ситуацию, и др.

Визуальное дешифрирование, являвшееся долгое время основным методом интерпретации данных ДЗЗ, трудоемко, не всегда эффективно и иногда бывает невозможно, например, при исследовании снимков с большим количеством спектральных каналов. Кроме того, сложным является визуальное распознавание изображений объектов, чьи размеры или размеры их деталей находятся на границе пространственного разрешения снимка. Поэтому целесообразно использовать автоматизированные методы классификации. Однако, классификация космических изображений существующими попиксельными методами, реализованными в стандартных программных продуктах для обработки данных ДЗЗ, не всегда приводит к корректным результатам. Программные средства, использующие информацию о структуре изображений, полученных современными съемочными средствами, также не всегда обеспечивают необходимое качество решения поставленных задач.

В настоящее время происходит постоянное совершенствование систем дистанционного зондирования, что позволяет получать снимки всё более высокого спектрального и пространственного разрешения. Существуют системы, позволяющие вести съемку в сотнях спектральных диапазонов. Поскольку каждый диапазон характеризует те или иные особенности объектов, многозональность и гиперзональность изображений играет важную роль при распознавании. Линейное разрешение снимков также постоянно улучшается. Если в 70-х годах каждый пиксель космического снимка соответствовал 80 метрам Земли, то сейчас обычной практикой являются снимки с разрешением в 1 метр и меньше. Традиционные методы, разработанные для снимков с невысоким разрешением, не позволяют извлечь всю полезную информацию для современных данных ДЗЗ. Поэтому существует необходимость в новых методах интерпретации изображений площадных объектов местности.

Таким образом, задача разработки метода интерпретации многозональных изображений высокого разрешения площадных объектов местности является актуальной.

Степень разработанности темы.

Исследования в области интерпретации площадных объектов местности на основе данных дистанционного зондирования Земли представлены в работах как российских, так и зарубежных авторов: Аковецкий В.И., Живичин А.Н., Кравцова В.И., Лабутина И.А., Мурынов А.И., Савиных В.П., Anderson J.R., Chandra A.M., Congalton R.G., Foody G.M., Haralick R.M., Schowengerdt R.A. Все перечисленные авторы подчеркивают важность развития работ по интерпретации данных ДЗЗ в направлении поиска эффективных признаков и методов принятия решений.

Существует множество программных продуктов, предназначенных для работы с мультиспектральными данными, для их обработки и последующей интерпретации. Прежде всего, это ENVI, ERDAS, Opticks, ER Mapper, IDRISI. Основным недостатком перечисленных систем, с точки зрения решения поставленной задачи, является попиксельная классификация, формирующая вектор признаков только из значений яркостей пикселей в разных каналах снимка или из вегетационных индексов, что недостаточно при работе с текстурными изображениями. Другие программы, в которых предусмотрено использование структурных признаков, также не позволяют получать результаты классификации трудноразличимых объектов с приемлемой точностью.

Цель работы – разработать и исследовать метод интерпретации многозональных космических изображений площадных объектов местности, который учитывает структурные и спектральные особенности изображений и с высокой точностью принимает решение о принадлежности объекта к классу.

Для достижения поставленной цели необходимо решить следующие **задачи**:

1) выполнить анализ существующих систем признаков и методов принятия решений, используемых для классификации многозональных изображений, с учетом требований задачи интерпретации изображений площадных объектов

местности и современных возможностей средств дистанционного зондирования Земли;

2) разработать систему признаков, которая способна наиболее полно описывать изображения площадных объектов местности с использованием спектральных и структурных особенностей материалов съемки;

3) разработать метод классификации, который способен работать как с дискретными, так и с непрерывными признаками, оценивать информативность признаков и принимать решение на основе вычисления оценок принадлежности объекта к классам;

4) провести экспериментальные исследования предложенных признаков и метода при классификации модельных текстур и изображений площадных объектов местности на реальных данных многозональной космической съемки;

5) исследовать возможности применения разработанной системы признаков для решения задач анализа материалов многозональной съемки с низколетящих летательных аппаратов.

Объектом исследования выступают многозональные космические снимки площадных объектов местности и системы их интерпретации.

Предметом исследования являются дешифровочные признаки изображений, основанные на использовании вейвлет-преобразования, и методы классификации изображений объектов.

Научная новизна работы состоит в следующем:

1) выполнен системный анализ задачи интерпретации космических снимков площадных объектов местности, в результате которого подтверждена необходимость разработки нового метода интерпретации, учитывающего пространственные и спектральные особенности изображений площадных объектов и способного решать поставленную задачу с высокой точностью;

2) предложена и исследована система признаков, вычисляемая на основе вейвлет-преобразования изображений площадных объектов местности. В качестве отдельных признаков используются статистические и структурные характеристики результатов двумерного дискретного вейвлет-преобразования;

3) разработан метод классификации, содержащий процедуры дискретизации значений признаков, оценки значимости признаков и принятия решений на основе оценок принадлежности объекта к классам;

4) в результате экспериментальных исследований на модельных примерах и реальных данных космической съемки были определены наилучшие параметры разработанного метода, обеспечивающие наиболее высокие показатели точности. В число таких параметров метода интерпретации входят: вид вейвлет-функции; уровень вейвлет-преобразования; количество сегментов области значений признаков; пороговое значение функции значимости;

5) разработан метод выявления областей местности с характерными свойствами по мультиспектральным данным, полученным с беспилотных летательных аппаратов, с использованием системы из вейвлет-признаков. Метод основан на отборе наиболее информативных признаков вдоль базовой линии настройки метода.

Практическая значимость работы

Разработанный метод интерпретации многозональных изображений площадных объектов местности способен с высокой точностью решать практические задачи классификации трудноразличимых объектов растительности.

Разработанный метод выявления областей местности с характерными свойствами по мультиспектральным данным, полученным с беспилотных летательных аппаратов (БПЛА), позволяет определять участки перспективные с точки зрения наличия археологических памятников.

Методология и методы исследования. В ходе диссертационного исследования применялись методы распознавания образов, статистические методы обработки данных, методы цифровой обработки изображений, методы дешифрирования аэрокосмических снимков. Построение системы признаков было основано на теории вейвлет-анализа сигналов и изображений. Разработка метода принятия решения была основана на концепции алгоритмов, основанных на вычислении оценок, и алгоритме распознавания объектов в условиях неполноты

информации. Разработка программ и проведение экспериментов проводилось в среде программного продукта Orticks 4.11.0 на языке программирования Python.

Положения, выносимые на защиту:

- 1) результаты системного анализа задачи интерпретации космических снимков площадных объектов местности (п.2);
- 2) система признаков интерпретации многозональных изображений лесной растительности, построенная на основе вейвлет-преобразования (п.4, 5);
- 3) метод классификации, относящийся к семейству алгоритмов распознавания, основанных на вычислении оценок (п.4, 5), включающий в себя процедуру оценивания информативности признаков (п.3, 11);
- 4) результаты экспериментальных исследований на модельных текстурах из альбома Бродаца и на космических снимках разных съемочных систем (п.3, 12);
- 5) метод выявления областей местности с характерными свойствами по мультиспектральным данным, полученным с беспилотных летательных аппаратов (п.5, 12).

Достоверность выводов и результатов обеспечивается корректным использованием методов обработки изображений и математических методов обработки результатов экспериментальных исследований, подтверждается отсутствием противоречий с известными положениями и воспроизводимостью экспериментальных результатов, подтверждением результатов на нескольких наборах данных, включая снимки с разных съемочных систем.

Апробация результатов работы. Полученные результаты докладывались и обсуждались на следующих конференциях: Всероссийской Школе-Конференции Молодых Ученых «КоМУ-2013» - Ижевск, 2013; Всероссийской научно-практической конференции «Инновации в науке технике и технологиях» - Ижевск, 2014; X, XI и XII Международных научно-технических конференциях «Приборостроение в XXI веке. Интеграция науки, образования и производства», 2014, 2015 и 2016 (дипломы второй и первой степени); IV Всероссийской конференции «Химическое разоружение-2015: итоги и аспекты технологических решений, экоаналитического контроля и медицинского мониторинга «CHEMDET-

2015» - Ижевск, 2015; представлялись на Всероссийской научно-практической конференции студентов, аспирантов, молодых ученых и специалистов «Энергосбережение и инновационные технологии в топливно-энергетическом комплексе» - Тюмень, 2014; на Международной научной конференции МКО-2015-05; на ежегодных Региональных научно-технических конференциях «Информационные технологии в науке, промышленности и образовании», г. Ижевск (2015 и 2016 гг.).

Реализация результатов работы.

Результаты диссертационной работы использованы в рамках госбюджетной НИР "Разработка и исследование электромагнитных и акустических методов диагностики пространственной структуры неоднородных сред, предельных состояний материалов, технических систем и методов пространственной локализации областей с характерными свойствами", № государственной регистрации 01201352089.

Результаты диссертационной работы использованы при выполнении работ по Соглашению о сотрудничестве с Министерством лесного хозяйства Удмуртской Республики от 01 июня 2013 года для исследования возможностей обеспечения организации рационального, многоцелевого, непрерывного и неистощительного лесопользования, воспроизводства, охраны и защиты лесов по материалам многозональной космической съемки.

Тематика диссертационной работы поддержана грантом Российского Фонда Фундаментальных Исследований (проект № 15-06-04239 а).

Результаты разработки специализированного программного обеспечения зафиксированы в виде Свидетельства о государственной регистрации программы для ЭВМ «Программное обеспечение определения разновидностей объектов растительности по их многозональным изображениям» № 2016613178 от 18.03.2016.

Публикации. Результаты работы отражены в 13 публикациях, в том числе в 4 изданиях, рекомендованных ВАК.

Личный вклад автора.

Алгоритмы, методики и эксперименты, проведенные на модельных и реальных данных, анализ и интерпретация результатов экспериментов, представленные в диссертации, получены автором лично.

Предложенный метод интерпретации космических снимков площадных объектов местности разработан в соавторстве с научным руководителем, к.т.н., старшим научным сотрудником Миличем В.Н. Математическое обоснование метода классификации и теоретическая оценка контрольной выборки выполнены в соавторстве с к.ф.-м.н, доцентом Ицковым А.Г.

Выбор приоритетов, направлений, методов исследования, формирование структуры и содержания работы выполнено автором при участии научного руководителя к.т.н., старшего научного сотрудника Милича В.Н.

Автором лично предложена схема классификации, включающая процедуры дискретизации значений признаков, оценки значимости признаков и процедуру принятия решений на основе оценок принадлежности объекта к классам. Кроме того личный вклад автора заключается в выполнении анализа процедур вейвлет-преобразования изображений с целью поиска наиболее эффективных вариантов, реализации конкретных алгоритмов вейвлет-преобразования, разработке и реализации алгоритма отбора эффективных признаков изображений и метода принятия решений. Автором выполнены работы по разработке программ и проведению экспериментальных исследований с изображениями из альбома текстур Бродаца и изображениями съемочных систем RapidEye и QuickBird. Выполнено обобщение результатов и сделаны выводы об эффективности предлагаемого метода.

Полученные лично соискателем результаты представлены в работах:

- результаты системного анализа задачи интерпретации космических снимков площадных объектов местности, в результате которого подтверждена необходимость разработки нового метода интерпретации, учитывающего пространственные и спектральные особенности изображений площадных объектов, способного решать поставленную задачу с высокой точностью, доложены на конференции «Приборостроение в XXI веке. Интеграция науки,

образования и производства» (Ижевск, 23 ноября - 25 ноября, 2016 г.) и представлены в материалах этой конференции;

- в работах [48, 49] предложено использование системы признаков, сформированной из статистических характеристик результатов двумерного дискретного вейвлет-преобразования. Проведены исследования по классификации объектов на снимке QuickBird с признаками, построенными на основе вейвлет-преобразования Хаара и Добеши, которые позволили получить точность классификации не ниже 70 %;

- в работах [46, 50, 51] проведены исследования по анализу влияния уровня вейвлет-преобразования при формировании системы признаков на результаты применения разработанного метода интерпретации. Увеличение уровня вейвлет-преобразования позволило при классификации трудноразличимых объектов лесной растительности, отличающихся видовым составом и возрастом, получить результаты классификации с точностью не ниже 80 %;

- в работах [47, 52, 53, 54, 55] предложен и исследован метод классификации, относящийся к разделу алгоритмов, основанных на вычислении оценок, включающий в себя процедуру оценки наиболее информативных признаков. Проведены исследования зависимости результатов классификации от параметров метода, в результате чего выявлены параметры, способные обеспечивать точность классификации не ниже 90 %. В ходе исследования рассматривалось 5 вейвлет-функций (Хаара, Добеши, Шеннона-Котельникова, симлет, койфлет);

- в работах [25, 56] разработан метод выявления областей местности с характерными свойствами по материалам многозональной съемки с низколетящих беспилотных летательных аппаратов. Метод базируется на разработанной системе признаков, основанных на вейвлет-преобразовании. Рассмотрена задача определения территорий с наибольшей мощностью гумусированного слоя земли, решение которой позволяет определять участки перспективные с точки зрения наличия археологических памятников. Результат применения разработанного

метода позволил говорить о высоком уровне соответствия полученных и справочных данных;

- зарегистрировано программное обеспечение определения разновидностей объектов растительности по их многозональным изображениям (Свидетельство о государственной регистрации программы для ЭВМ [66], см. Приложение С).

Структура и объем диссертации. Диссертационная работа состоит из введения, четырех глав, заключения и списка литературы. Объем диссертации составляет 158 страниц, работа содержит 36 рисунков. Список литературы насчитывает 143 наименования.

В **первой главе** представлен обзор литературы, который включает ссылки на работы как российских, так и зарубежных авторов. В обзоре рассмотрены основные понятия и термины, отражены особенности данных ДЗЗ, а также представлены этапы интерпретации мультиспектральных данных. Кроме того, рассмотрены существующие подходы к формированию систем признаков (вегетационные индексы, текстурные признаки, признаки Харалика и др.) и методы принятия решения, используемые в работах рассматриваемого направления. Приведена сравнительная таблица наиболее значимых работ последних лет по классификации мультиспектральных данных с целью их интерпретации. Сформулированы задачи исследования.

Во **второй главе** представлен системный анализ задачи интерпретации площадных объектов местности, изложены теоретические понятия, примененные при разработке предложенного метода и используемой системы признаков. Представлены понятия вейвлет-анализа, проанализированы особенности некоторых вейвлет-функций, способы быстрого двумерного дискретного вейвлет-преобразования. Описан предлагаемый метод принятия решений, относящийся к разделу алгоритмов распознавания, основанных на вычислении оценок. Метод использует для отбора наиболее информативных признаков функцию значимости и основан на алгоритме распознавания объектов в условиях неполноты информации.

В **третье главе** представлена система признаков, основанная на вейвлет-преобразовании. Приведены результаты исследований предложенной системы при использовании модельных текстурных изображений из альбома Бродаца, а также при исследовании снимков съемочных систем QuickBird и RapidEye.

В **четвёртой главе** приведены результаты применения предложенных системы признаков и метода принятия решений при исследовании шести классов объектов лесной растительности на снимке QuickBird; при исследовании шести классов объектов лесной растительности на снимке RapidEye; при обнаружении областей местности с характерными свойствами (областей с большей мощностью гумусированного слоя) на снимке с БПЛА. Представлены результаты исследования зависимости результатов классификации от параметра метода - количество сегментов в разбиении диапазонов значений признаков.

Глава 1. Модели и методы обработки данных дистанционного зондирования

1.1. Данные дистанционного зондирования Земли

Дистанционное зондирование - это «метод получения информации об объекте, участке поверхности или явлении путем анализа данных, собранных без контакта с изучаемым объектом» [75]. В широком смысле «дистанционное зондирование Земли – это получение любыми неконтактными методами информации о поверхности Земли» [65]. Шовенгердт Р.А. [78] дает следующее определение: «Дистанционное зондирование Земли является методом измерения свойств объектов на земной поверхности, в котором используются данные, полученные с помощью воздушных летательных аппаратов и искусственных спутников Земли». В отечественной литературе [71] дается другое определение ДЗЗ: «Под дистанционным зондированием поверхности Земли понимается наблюдение и измерение энергетических и поляризационных характеристик излучения объектов в различных диапазонах электромагнитного спектра с целью определения местоположения, вида, свойств и временной изменчивости объектов окружающей среды без непосредственного контакта с ним измерительного прибора».

Данные дистанционного зондирования Земли (ДЗЗ), получаемые с космических спутников, являются цифровыми изображениями, которые представимы матрицами дискретных значений пикселей и характеризуются пространственным, спектральным и радиометрическим разрешением [78]. Под пространственным разрешением снимка понимается «размер на местности самой малой детали, воспроизведенной на снимке» [39]. Возможность многозональной съемки при дистанционном зондировании обеспечивается тем, что съемочная система, размещенная на летательных аппаратах или космических спутниках, фиксирует отраженный солнечный свет сразу в нескольких диапазонах электромагнитного спектра. Поскольку объекты земной поверхности обладают разной отражательной способностью в различных спектральных зонах, то такие

снимки отражают различительные особенности тех или иных объектов, находящихся в разных состояниях. Ширина каждого спектрального диапазона определяет спектральное разрешение данных ДЗЗ. Радиометрическое разрешение определяется количеством уровней дискретизации яркостей солнечного излучения, отраженного объектом. Или, другими словами, радиометрическое разрешение «определяется чувствительностью сенсора к вариациям интенсивности электромагнитного излучения» [75].

Таким образом, многозональные изображения являются данными, полученными в результате фиксирования солнечного света, отраженного объектами земной поверхности, в нескольких диапазонах электромагнитного спектра съемочной аппаратурой, размещенной на летательном аппарате, и представленными в цифровом виде. Многозональные изображения характеризуются своим пространственным, спектральным и радиометрическим разрешением.

Мультиспектральные данные дистанционного зондирования Земли широко применяются в следующих областях [75, 71, 30, 42]:

- лесное хозяйство (лесотаксация, определение видового состава, определение состояния лесных массивов и др.);
- мониторинг состояния окружающей среды (мониторинг загрязнения окружающей среды, определение последствий катастроф, экспресс-анализ при экоаналитическом мониторинге и др.);
- сельское хозяйство (оценка вида, состояния посевов и их продуктивности и др.);
- инвентаризация пространственных объектов на определенной территории;
- отслеживание несанкционированных изменений (вырубки, незаконные застройки и др.);
- картографирование территорий;

- обнаружение территорий с характерными свойствами (областей растительности, пораженных вредителями; участков земли, подвергнутых внешнему воздействию и др.).

Широкое применение мультиспектральных данных ДЗЗ можно объяснить рядом их преимуществ: объективность, актуальность, многозональность, обзорность и доступность [71, 30]. Объективность и актуальность данных ДЗЗ состоит в том, что они отражают действительное состояние территории на момент съемки. Многозональность заключается в представлении особенностей объектов в разных диапазонах электромагнитного спектра. Обзорность подразумевает получение данных соответствующего разрешения на значительные по размерам площади. Доступность обеспечивается архивами снимков ДЗЗ и возможностью съемки любых территорий в любое время.

Современный этап развития ДЗЗ связывают с запуском искусственного спутника Landsat в 1972 году, съемочная аппаратура которого вела съемку поверхности Земли в 4 спектральных каналах с шириной 100 нм и пространственным разрешением 80 м [78]. С тех пор произошел значительный прогресс в системах получения данных ДЗЗ. Сегодня существуют системы, ведущие гиперзональную съемку, а также системы, способные предоставлять снимки сверхвысокого разрешения (до 0.5 м). Основными источниками снимков ДЗЗ выступают такие страны как США, Россия, Китай, Индия, Франция, Германия. В таблице 1 приведены некоторые спутники и их краткие характеристики [36].

Таблица 1 - Основные искусственные спутники ДЗЗ

Спутник (страна)	Год	Разрешение		Количество каналов	Период съемки, сутки
		Пространственное, м	Радиометрическое, бит/пиксель		
Ресурс-ДК1 (Россия)	2006	2 - 3	10	3	6
Ресурс-П №1, №2 (Россия)	2013, 2014	3 - 4	—	6	3

Продолжение таблицы 1

Спутник (страна)	Год	Разрешение		Количество каналов	Период съемки, сутки
		Пространственное, м	Радиометрическое, бит/пиксель		
WorldView-3 (США)	2014	1,24	11	8	1
QuickBird (США)	2001	2,44	11	4	1 - 5
Landsat-7,8 (США)	1999, 2013	30	8, 12	4 5	16
Ресурс-ДК1 (Россия)	2006	2 - 3	10	3	6
Aqua/MODIS (США)	2002	1000	12	36	2
GF-2 (Китай)	2014	3,24	10	4	5
RapidEye (Германия)	2008	6,5 (5)	12	5	1
Resourcesat-2 (Индия)	2011	5,8	10	3	5
SPOT-6,7 (Франция)	2012, 2014	8	12	4	–

В зависимости от решаемой задачи необходимо учитывать несколько показателей при выборе снимков [8]: пространственное разрешение; ширина полосы съемки; спектральный диапазон съемки и количество зон; радиометрическое разрешение; периодичность съемки.

Для работы со снимками ДЗЗ существуют специализированные программные системы. Среди наиболее используемых ENVI, ERDAS, Opticks, ER Mapper, IDRISI [71].

Программный комплекс ENVI (Environment for Visualizing Images), разработанный компанией ITT Visual Information Solutions обеспечивает полный цикл обработки данных ДЗЗ и их интеграции с данными ГИС (географическая информационная система). Встроенный язык программирования IDL (Interactive

Data Language) позволяет создавать собственные алгоритмы для решения специализированных задач. Комплекс обладает набором различных инструментов, которые позволяют проводить фотограмметрическую обработку, интерактивные процедуры визуального улучшения изображений, строить запросы, выполнять дешифрирование и классификацию. При классификации возможно использование значительного количества методов, среди которых алгоритмы кластеризации K-means, ISODATA, алгоритмы минимального расстояния, метод максимального правдоподобия, нейронные сети, дерево принятия решений (эти алгоритмы будут рассмотрены в разделе «Методы классификации»). Программный комплекс ENVI является удобным средством, позволяющим проводить разнообразные операции с данными ДЗЗ.

Программный пакет ERDAS Imagine, выполненный в виде растрового графического редактора с множеством дополнительных специфических функций, позволяет производить различные преобразования изображений, снабжать их географической информацией, подготавливать данные для дальнейшего их использования в ГИС и системах автоматизированного проектирования. Большой выбор инструментов ERDAS Imagine позволяет не только обрабатывать данные, но и представлять их в различных форматах, в том числе в виде 3D-моделей. Программа поддерживает процедуры ортотрансформирования и создания стереоскопических изображений. Кроме этого, ERDAS Imagine имеет возможности для расширения за счет инструментов написания и внедрения пользователем собственных модулей.

Программный комплекс Opticks поддерживает обработку данных ДЗЗ, в том числе многозональных, гиперзональных изображений, радарных снимков. Включены различные операции визуального улучшения изображений, процедуры классификации, кластеризации. Среди доступных методов классификации: метод спектрального угла (SAM), ACE (Adaptive Cosine Estimator), CEM (Conditional Expectation Maximization), методы минимального расстояния, алгоритм K-means. Opticks отличает его открытый исходный код и расширенный диапазон функций, существующих у известных программных комплексов ДЗЗ. В Opticks

предусмотрена возможность использования языков IDL, Python. Кроме того, безусловным преимуществом является его бесплатное распространение. Для реализации настоящего исследования было выбрано программное обеспечение Opticks 4.11.0 по причине возможности написания собственных функций на языке Python и свободного доступа.

На рисунке 1 изображена схема общей методики анализа многозональных изображений. Согласно этой схеме, каждое исследуемое изображение сначала проходит этап анализа, в ходе которого происходит выбор исследуемых классов объектов и признаков (характеристик, которыми будут описаны объекты на снимке), а также выбор эталонных образцов и расчет для них признаков. Этап интерпретации, состоящий из расчета признаков и сравнения их значений с эталонами, выполняется каждый раз для вновь предъявленного тестового образца.

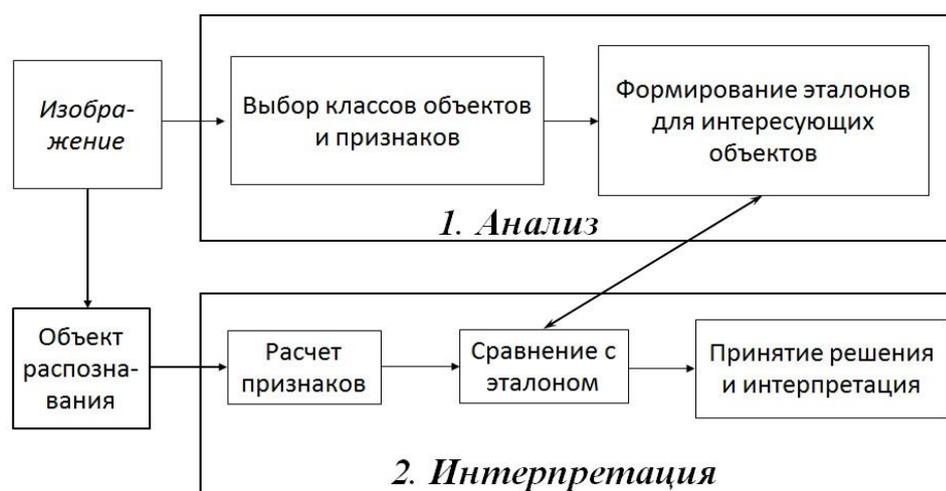


Рисунок 1- Методика анализа изображений в целях их интерпретации

Таким образом, данные дистанционного зондирования Земли несут в себе большой объем полезной информации, для извлечения которой необходимо выполнить определенные процедуры коррекции, улучшения качества изображения и ключевые процедуры интерпретации космического снимка.

1.2. Задача интерпретации изображений площадных объектов местности по данным дистанционного зондирования

Конечная цель обработки данных дистанционного зондирования Земли зависит от конкретного исследования и области применения. Общие задачи обработки данных ДЗЗ можно представить следующим списком: обнаружение объектов, оконтуривание границ, определение типа объектов, распознавание и определение характеристик обнаруженных объектов. Обнаружение предполагает определение конкретных фрагментов на снимке, представляющих интерес. Оконтуривание объектов заключается в геометрической привязке их границ к местности. Определение типа позволяет выявить исследуемое множество классов объектов. Этап распознавания подразумевает соотнесение каждого исследуемого объекта с одним из классов. Определение характеристик направлено на более детальное описание распознанных объектов.

Принято выделять следующие типы пространственных объектов на снимках [65]: компактные (точечные), линейные и площадные.

Компактные объекты локализуются в небольшой части пространства. При картографировании такие объекты изображают некоторым условным знаком, который характеризует место, где находится этот объект, а также его тип (столб, дерево, водонапорная башня и др.).

Линейные объекты являются пространственно-протяженными. Они характеризуются тем, что один из их геометрических параметров значительно больше другого. Например, длина дороги значительно больше её ширины. При составлении карт такие объекты отмечают линиями. При этом ширина не отображается в масштабе карты, а представляется численной характеристикой. Характерные представители линейных объектов на снимке – это дороги, реки, линии электропередач, границы между лесом и полем.

Площадные объекты имеют границы и выражаемую в масштабе карты площадь. Такие объекты внутри обозначенных границ имеют однородные

свойства. Наиболее характерные представители на снимке – это леса, луговая растительность, садовые массивы, кварталы городской застройки, поля и т.п.

Все объекты местности характеризуются, в первую очередь, своей пространственной структурой, которая определяется размерами и формой объекта и составляющих его элементов, а также характером их пространственного размещения. Различия в отражательной способности объектов и их элементов в различных зонах спектра, а также собственные и падающие тени обеспечивают возможность визуального восприятия этой структуры как непосредственно на местности (при полевом обследовании), так и на панхроматических и многозональных снимках земной поверхности [9, 38, 78].

Понятие структуры означает «совокупность устойчивых связей объекта, обеспечивающих сохранение его основных свойств при различных внешних и внутренних изменениях» [10]. Непосредственно из определения вытекают такие особенности структуры, как ее составной, изменчивый и организованный (упорядоченный) характер. Пространственная структура компактных объектов, в частности, представляется совокупностью элементов их формы, связанных определенным образом в единое целое, а вариации формы и размеров обуславливают ее изменчивость. Пространственная структура линейных объектов характеризуется, например, лентообразной извилистой формой рек и практически прямолинейной формой дорог. Структура растительного покрова, то есть распределение массы растений в пространстве, характеризуется ярусностью и мозаичностью фитоценоза и в то же время имеет существенно случайный (стохастический) характер [16]. Смена фенологических фаз и аспектов определяет ее изменчивость. Для грунтов структура образуется различными формами микрорельефа поверхности (бугры, барханы, гряды, полигональные образования), а также чередованием участков с различной степенью увлажнения. Характеристики таких структур также существенно случайны. У лесных массивов наблюдается частичная упорядоченность (регулярность) структуры древостоев, обусловленная характером произрастания элементов растительного сообщества. Таким образом, пространственная структура объектов местности имеет составной,

изменчивый и регулярно-стохастический характер. Изменчивость и степень регулярности определяется как природными, так и антропогенными факторами.

При космической съемке земной поверхности изображения объектов формируются в результате прохождения отображенного ими светового потока по каналу, состоящему из атмосферы и оптико-съёмочной системы сканера. При этом пространственная структура объектов местности отображается в виде структуры изображения на снимке (многозональном снимке) [1, 22, 78]. Изображения объектов местности формируются в зависимости от оптико-геометрических условий съемки и состояния атмосферы. Поскольку отдельные детали объектов местности воспроизводятся в виде элементов изображения на снимке, то структура изображений объектов также носит составной, изменчивый и регулярно-стохастический характер. Кроме того, в процессе формирования изображений канал передачи информации оказывает дополнительное воздействие, заключающееся в пространственно-частотных искажениях, которые ведут к потере пространственного разрешения. Это воздействие приводит к размытию структуры изображений объектов местности и радиометрическим искажениям, обусловленным светорассеянием в атмосфере (дымка), которые приводят к искажениям шкалы тонопередачи и цветопередачи и снижению контрастов. Причем, степень воздействия различна в различных зонах спектра [75, 78]. Влияние этих воздействий приводит к усилению изменчивости структуры изображения, усилению стохастичности и размытию структуры, то есть к ухудшению изобразительных свойств снимка и к уменьшению надежности интерпретации изображений объектов. Зрительный анализатор человека плохо приспособлен к восприятию размытых искаженных и зашумленных изображений. Если размеры элементов структуры соизмеримы с линейным разрешением снимка на местности, а контрасты слабы, то такие структуры не воспринимаются и не интерпретируются, то есть являются трудноразличимыми [9, 22]. Вместе с тем, часть информации об объектах местности, уходя под порог визуального восприятия, на изображении сохраняется. Этот вывод подтверждается при использовании цифровых методов фильтрации изображений, когда

расфокусированное изображение, не воспринимаемое зрительным анализатором человека, после автоматической обработки практически полностью восстанавливается [62, 80].

Для устранения случайных и систематических ошибок, которые связаны, например, с влиянием атмосферы и рельефа [78], необходима их коррекция. Существует несколько типов преобразований, которые служат разным целям: атмосферная, радиометрическая, геометрическая коррекции.

При дистанционном зондировании Земли из космоса отраженное солнечное излучение проходит через атмосферу, влияющую на итоговое излучение, зафиксированное датчиком. Существует три основных алгоритма атмосферной коррекции: стандартная абсолютная коррекция, стандартная относительная коррекция и исправления на основе заданных моделей [71]. Радиометрическая коррекция приводит яркости пикселей объектов к их истинным значениям, искажённых влиянием атмосферы, рельефа, ошибками датчиков. Геометрическая коррекция устраняет ошибки, связанные с изменением высоты, скорости полета спутника, с возникновением угла по отношению к надиру или с другими изменениями пространственного расположения съемочной аппаратуры [29].

Поскольку площадные объекты на мультиспектральных данных характеризуются не только своими спектральными особенностями, но и пространственным расположением элементов структуры, то система признаков должна включать в себя характеристики, которые описывают, и частотные, и пространственные особенности рассматриваемых изображений (образцов).

Рассмотрим возможности использования структуры изображений объектов местности для их распознавания. При визуальном дешифрировании космических снимков параметрами различимости выступают тон и структура изображений. Согласно Живичину [22], вероятность распознавания определяется зависимостью

$$P = \exp \left[- \left(B \frac{A}{L} \right)^2 \right], \quad (1)$$

где L – максимальный размер объекта на местности; A – минимальный размер различимой детали на местности; B – коэффициент распознавания формы объекта. На рисунке 2 приведены графики вероятности визуального распознавания при $B=1$ (синяя линия), $B=1.5$ (зелёная линия), $B=3$ (красная линия).

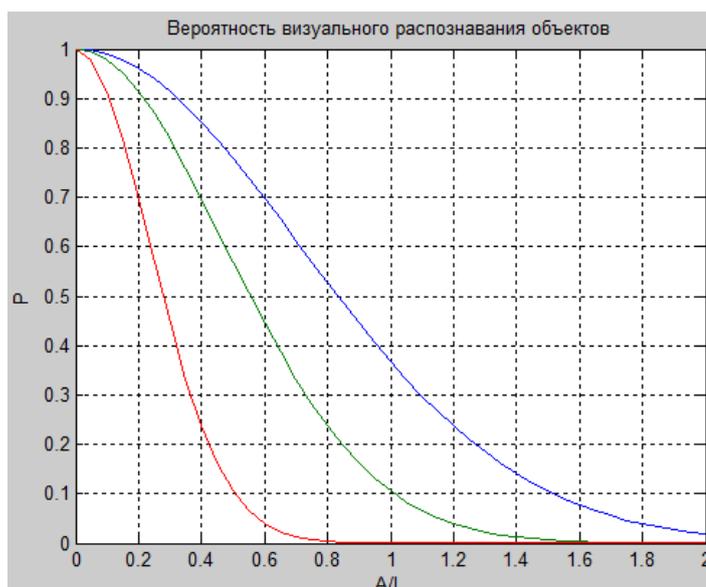


Рисунок 2 - График зависимости вероятности визуального распознавания по Живичину от отношения A/L

Предполагая $A \approx L$, что характерно, в частности, для изображений лесной растительности, из формулы (1) получаем $P = \exp[-B^2]$. Согласно Живичину [22] значения коэффициента B находятся в диапазоне от 1 до 3. Тогда получим, что P не превосходит 0.35.

Если задаться требуемой вероятностью распознавания на уровне 0.7 – 0.8, по формуле определить отношение A/L , то его величина составит 3.0 – 4.0. Эти данные подтверждаются результатами [45], где установлено, что для уверенного распознавания объекта необходимо, чтобы размер его изображения или деталей, как минимум, в 3 раза превышал величину пространственного разрешения снимка. Тогда при исследовании таких объектов, как лесная растительность, для уверенного распознавания необходимы изображения с разрешением менее 1 м.

Таким образом, степень различимости объектов определяется соотношением размеров их деталей и пространственного разрешения снимка. Если пространственное разрешения снимка находится на границе или меньше размеров деталей объекта, то такие объекты считают трудноразличимыми [22].

1.3. Методы и алгоритмы анализа данных дистанционного зондирования

При интерпретации изображений все объекты распознавания, которыми могут выступать, как отдельные пиксели, так и их группы, описываются некоторым набором признаков, который затем используется при принятии решений, что отображено на рисунке 1.

Выбор системы признаков во многом является ключевой задачей классификации, особенно, при рассмотрении трудноразличимых объектов. Набор значений системы признаков, рассчитанный для конкретного объекта, будем в дальнейшем называть вектором признаков. При интерпретации многозональных изображений в число признаков могут входить характеристики как отдельных пикселей, так и их сочетаний.

Вегетационные индексы (ВИ) – это показатели, получаемые в результате операций над значениями пикселей в разных спектральных каналах [78]. К настоящему времени существует около 160 ВИ, полученных на основе эмпирических исследований [76]. Основная идея, заложенная в ВИ, состоит в том, что данные, получаемые в результате различных математических операций со значениями яркостей пикселей в разных спектральных каналах, позволяют извлекать дополнительную полезную информацию о состоянии растительности на снимке.

Самый распространенный ВИ – это индекс NDVI (Normalized Difference Vegetation Index), вычисляемый по формуле:

$$NDVI = (NIR - RED) / (NIR + RED),$$

где NIR, RED – значения яркостей соответственно в ближнем инфракрасном (ИК) и красном диапазонах. NDVI принимает значения в диапазоне от -1 до 1. Впервые был предложен в 1969 году [76]. NDVI показывает эффективность при распознавании растительности, поскольку оценивает количество фотосинтетической активной биомассы. Это подтверждают работы, исследовавшие применение NDVI для определения биологической продуктивности фитоценозов [41, 69] и оценки состояния растительности [28].

Широкий список вегетационных индексов может быть найден в [76]. Важно отметить, что ВИ не описывают пространственные особенности объектов и их деталей и, следовательно, не позволяют получать информацию о структуре изображений объектов, что необходимо учитывать при исследовании изображений таких объектов как лесная растительность.

Рассмотрим признаки, характеризующие пространственные особенности объектов. Под текстурными признаками понимают характеристики взаимного пространственного расположения пикселей. «Текстура - это матрица или фрагмент пространственных свойств участков изображений земной поверхности с однородными статистическими характеристиками» [59]. При работе с космическими снимками под текстурными изображениями обычно понимают «изображения распределенных объектов, составленных из точек, пятен, штрихов и других локальных структурных элементов, образующих неупорядоченный или малоупорядоченный массив в поле изображения, причем часто сами структурные элементы не разрешаются изображающей или регистрирующей системой» [43].

Далее будут рассмотрены некоторые из текстурных признаков, более детальный обзор которых можно найти в работах [32, 72]. Текстура во многом определяется размером рассматриваемой окрестности. Было выявлено [59], что если исследовать участки размером 3×3 , 5×5 , то статистические текстурные показатели характеризуют перепады яркости, а не сами текстуры. С другой стороны, большие размеры окна могут оказывать негативное влияние на границы структур. В [72] показано, что наиболее оптимальным размером для исследования лесов, пастбищ является размер 20×20 .

Автокорреляционная функция описывает связь между данными одного ряда, взятыми с определенным сдвигом. Для изображения, представленного в виде двумерного массива пикселей, автокорреляция может быть определена так [61]:

$$A(\xi, \eta; i, j) = \frac{\sum_{m=i-W}^{i+W} \sum_{n=j-W}^{j+W} p(m, n)p(m - \xi, n - \eta)}{\sum_{m=i-W}^{i+W} \sum_{n=j-W}^{j+W} p^2(m, n)}, \quad (2)$$

где $p(m, n)$ – яркость пикселя с координатами (m, n) . Функция (2) вычисляется для каждой точки с координатами (i, j) и соответствующего смещения (ξ, η) для участка размером $(2W+1) \times (2W+1)$. Рассмотрим второй момент автокорреляционной функции:

$$T(i, j) = \sum_{\xi=-T}^T \sum_{\eta=-T}^T \xi^2 \eta^2 A(\xi, \eta; i, j). \quad (3)$$

Рассчитанный по формуле (3) показатель является текстурным признаком, который может использоваться при классификации зернистых структур [32]. В работе [7] автокорреляционная функция используется для анализа текстурных изображений.

Для формирования признаков нередко используют Фурье-преобразование. Дискретное Фурье преобразование двумерного сигнала $f(x, y)$ размером $N_x \times N_y$ определяется следующим образом [78]:

$$F(u, v) = \sum_{m=0}^{N_x-1} \sum_{n=0}^{N_y-1} f(m, n) e^{-2\pi i \left(\frac{um}{N_x} + \frac{vn}{N_y} \right)}$$

В работе [3] система признаков, построенная на основе Фурье-преобразования, была использована при экологическом мониторинге территории района Новосибирска. В другом исследовании [112] обосновывается использование коэффициентов Фурье-преобразования в качестве признаков. Более полное обоснование построения таких признаков можно найти в [32].

Признаки, основанные на статистических характеристиках, рассчитываются по одномерным или двумерным гистограммам, описывающим распределение яркостей пикселей. В работе [6] для классификации текстур предлагается использовать гистограммные характеристики в информационном базисе Грамма-Шмидта. Целесообразность использования этих признаков в указанной работе состоит в простоте их вычисления, инвариантности к влиянию поворотов и изменению масштаба.

Для получения признаков, которые способны характеризовать взаимное расположение пикселей, предложено [57, 73] использовать матрицу смежности. Элементами матрицы смежности p_{ij} являются относительные частоты наличия на изображении соседних элементов, которые расположены друг от друга на расстоянии d . При этом, как правило, рассматривают горизонтальные, вертикальные и диагональные пары элементов, которым соответствуют $\alpha = 0^\circ$, $\alpha = 90^\circ$, $\alpha = 45^\circ$ и $\alpha = 135^\circ$. В работе [139] авторы утверждают, что эффективным является использование матрицы смежности для формирования признаков вместе с самоорганизующимся методом нейронных сетей для классификации.

Признаки Харалика являются наиболее часто используемыми признаками, рассчитываемыми по матрицам смежности, называемым также матрицами распределения градиентов (Gray-Tone Spatial-Dependence Matrices). Признаки Харалика содержат информацию о различных текстурных характеристиках: об однородности, линейной зависимости тона (линейная структура), контрасте, количестве и природе границ и сложности изображения [107]. Хараликом было предложено 14 текстурных признаков, строящихся по матрицам смежности, полный список которых можно найти в литературе [107]. Такие признаки

получили широкое распространение и показали свою эффективность при классификации многозональных космических изображений [89, 88, 90, 119, 141]. В п. 1.6. представлены более подробные характеристики полученных результатов.

Рассмотренные выше признаки показывают свои преимущества при исследовании текстурных свойств изображений. Однако, этого недостаточно при рассмотрении многозональных изображений растительности, где важную роль имеет и информация о спектральных характеристиках изображенных объектов.

Вейвлет-признаками называют характеристики, рассчитываемые по результатам вейвлет-преобразования. Вейвлет-преобразование представляет собой разложение исходного сигнала по базису специально определенных функций, называемых вейвлетами [34]. Главной особенностью вейвлет-преобразования является его способность описывать исходный сигнал сразу в двух областях - частотной и пространственной. При обработке изображений используют двумерное дискретное вейвлет-преобразование (ДВП). Результатом его применения по схеме Малла [124] являются 4 изображения ДВП, характеризующие аппроксимацию, горизонтальные, вертикальные и диагональные элементы [19]. На рисунке 3 представлен пример результата применения одноуровневого ДВП к конкретному фрагменту многозонального изображения.

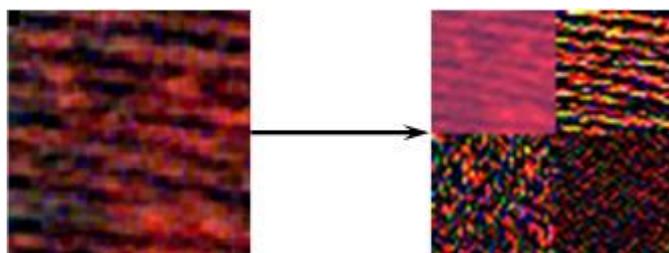


Рисунок 3 - Исходный образец и результат применения ДВП к фрагменту многозонального изображения размером 64×64 пикселей.

В последнее время вейвлет-преобразование все более широко используется для анализа многозональных космических изображений. Например, оно применяется для удаления шумов изображения [136], для сжатия данных

дистанционного зондирования [87], для сегментации изображения [98]. Но многие результаты показывают эффективность этой процедуры и при формировании признаков для интерпретации космических изображений. Вейвлет-признаки в виде функций от вейвлет-коэффициентов, получаемых в результате ДВП, использованы при анализе гиперзональных и многозональных изображений [114, 93, 100, 120, 126], и зарекомендовали себя как эффективный инструмент при интерпретации изображений. В приложении А подробно представлены характеристики полученных результатов некоторых из перечисленных работ.

В заключение обзора существующих признаков изображения рассмотрим эволюцию попыток построения систем признаков исходя из модельных представлений текстур. Необходимо отметить, что построенные таким образом системы признаков часто совпадают с системами, описанными ранее и построенными из других (часто эвристических) соображений. Представление о текстурах, как реализациях случайного поля, является общепринятым в работах по анализу текстурных изображений [5, 22, 67]. Поэтому вполне естественны предложения об использовании моментов распределения оптической плотности (средний тон, дисперсия, коэффициент асимметрии, эксцесс) в качестве аналитических признаков текстур. Однако, неадекватность такой модели очевидна, так как закон распределения оптической плотности не описывает взаимосвязи элементов, составляющих текстурное изображение. Поэтому необходимо наращивать систему статистических характеристик изображения, включив в нее параметры взаимосвязи элементов, что требует уточнения модели. Помимо использования традиционных методов статистического анализа случайных процессов и полей [22, 5, 67, 35, 63] в ряде работ были предложены такие признаки, как количество выбросов [116], характеристики автокорреляционной функции [22], характеристики распределения интервалов между выбросами [67], четыре центральных момента, медиана и энтропия распределений, интервал корреляции и ряд других.

Очевидно, что количество подобных признаков может наращиваться неограниченно, не гарантируя при этом получения полного описания. Поэтому более перспективным представляется подход, основанный на уточнении модели.

Учет пространственных взаимосвязей элементов текстуры может быть основан на существовании скрытой (стохастической) регулярности и периодичности их размещения. Для этой цели было предложено использовать признаки, основанные на измерении пространственных частот, например, путем анализа спектра Фурье изображения. Признаки, построенные на преобразовании Фурье, предложены в работах [26, 92, 99]. В [21] описаны признаки, полученные на основе использования периодограмм Бюй-Балло.

При всей многочисленности систем пространственно-частотных признаков необходимо отметить, что периодические свойства структуры изображений характерны далеко не для всех текстур, а, следовательно, адекватность таких моделей является, по крайней мере, неполной [73, 2, 74].

Система признаков, близкая к построенной по матрицам смежности, получается при использовании марковской модели текстурного изображения. Эта модель охватывает широкий класс случайных полей и основана на понятии марковского процесса [60]. В работе [44] показано, что использование признаков, в основе которых лежит модель одномарковского процесса дает неплохой результат, однако, экспериментальная проверка модели установила ее неадекватность. Марковская модель используется также в [40, 97, 109], но в этих работах рассматриваются не вопросы анализа текстурных изображений, а особенности их синтеза.

Наиболее сложными являются модели текстурных изображений, основанные на использовании понятия непроектируемого элемента, под которым понимается связное множество точек изображения, представляющее его локальную особенность. Признаки в этих моделях характеризуют как разнообразие локальных особенностей, так и их взаимосвязи на изображении. Подход, основанный на таких моделях, часто называют структурным или структурно-статистическим [73, 2, 74].

При структурно-статистическом подходе в качестве характеристик локальных особенностей чаще всего используются так называемые длины серий или длины хорд, которые характеризуют выбросы двумерного распределения оптической плотности текстурного изображения. Для каждого уровня селекции можно построить распределение значений длин серий, и характеристики этих распределений использовать в качестве признаков текстурного изображения. Такие признаки рассматриваются в работах [5, 67, 115]. Более приближенными к действительности представляются модели роста. Так, например, в работе [45] описана модель ПРСС (пространственно-распределенных стохастических структур), которая может быть использована для построения системы признаков. Такая модель предполагает действие стохастического порождающего процесса.

Структурно-статистические модели текстурных изображений наиболее полно учитывают такие их свойства, как случайный и составной характер, а также пространственную организацию не отдельных точек, а целых их образований (элементов). Недостатком указанных моделей является отсутствие способов надежной проверки их адекватности. Единственный метод такой проверки, приводящийся в литературе, - это синтез изображений текстур по построенной модели и их визуальное сравнение с оригиналами. Очевидно, что такая проверка адекватности недостаточна.

Таким образом, рассмотрение описанной эволюции представлений о текстурных изображениях от простейших параметрических моделей, где в качестве параметров используются системы эмпирико-эвристических признаков, до сложных структурно-статистических моделей, учитывающих особенности структуры отображаемых объектов, позволяет утверждать, что в теории моделей и признаков текстурных изображений в настоящее время получение адекватных моделей ограничивается их сложностью, что, в свою очередь, не позволяет произвести полный учет всех взаимосвязей между образующими текстуру элементами. Отсутствие адекватных моделей текстурных изображений отмечается в ряде работ (см., например, [6]). Эффективность моделей и систем признаков может оцениваться только экспериментальным путем.

В результате проведенного обзора можно сделать вывод о том, что не существует универсальной системы признаков пригодной для эффективного решения разных задач распознавания. Поэтому представляется целесообразным использовать такую систему признаков, которая могла бы объединить в себе разные виды информации (характеризующую и спектральные, и структурные особенности изображений объектов). Это подтверждают и другие исследования [11, 143]. Таким образом, для получения наиболее полного описания объектов распознавания, учитывающего разные виды информации, перспективным представляется вейвлет-преобразование.

1.4. Методы классификации и методы оценки точности

Интерпретация данных ДЗЗ реализуется в следующей последовательности процедур (см. рисунок 1): определяется набор исследуемых классов объектов (либо количество классов в задаче кластеризации); выбирается система признаков, позволяющая различать объекты; производится обучение алгоритма на выбранных заранее эталонных образцах, принадлежность которых к классами достоверно известна (обучение означает формирование векторов признаков для обучающих образцов и принятие их в качестве эталонов); для каждого исследуемого образца формируется вектор признаков и, в зависимости от конкретного алгоритма классификации, принимается решение, основанное на сравнении с эталонами. Процесс классификации считается завершенным, когда все исследуемые объекты отнесены к одному из классов.

Таким образом, одним из основных этапов интерпретации многозональных изображений является процесс их классификации, заключающийся в сравнении вычисленного вектора признаков с эталонами и принятии решения, т.е. в распознавании объектов. Целью этого этапа является отнесение каждого исследуемого образца или каждого пикселя (в случае попиксельной классификации) к одному классу. Различают два вида методов распознавания:

методы с контролируемым обучением и методы с неконтролируемым обучением (кластеризация) [78, 20].

Алгоритм К-средних (K-means) является наиболее общим для класса неконтролируемых методов [78]. Исследователю необходимо определиться с количеством классов, а также каждому классу назначить средний вектор признаков (центр класса). Затем для каждого объекта распознавания рассчитываются расстояния от его вектора признаков до всех средних векторов классов. На основании минимального расстояния объект присваивается к одному из классов. На следующем этапе (итерации) производится перерасчет центров классов. После перерасчета аналогично предыдущему этапу происходит переназначение всех объектов распознавания по классам. Для завершения такого итеративного процесса на каждой итерации i рассчитывается значение, характеризующее изменение расположения центров классов, $\Delta_i = \sum_{j=1}^K |\mu_j^i - \mu_j^{i-1}|$,

где K – количество классов, μ_j^i – средний вектор j -го класса на i -й итерации [78].

Как только это значение становится меньше заданного, процесс прекращается.

Существуют исследования, в которых настоящий метод применяется для классификации объектов по многозональным изображениям. Например, в работе [118] приводятся результаты классификации с общей точностью от 93 % до 95 %. Однако, при этом исследовались лишь 4 хорошо различимых класса объектов (водные объекты, хлопок, городские постройки, сухая растительность).

Ещё один широко применяемый метод кластеризации – итеративный самоорганизующийся метод анализа данных (ИСОМАД). Этот метод строится на тех же идеях, что и метод К-средних, однако, зависит от гораздо большего количества входных параметров, что позволяет адаптировать метод под разные цели исследования. В работах [79, 31] приводятся результаты исследования многозональных снимков, представленные в форме изображений, полученных после попиксельной кластеризации. При сравнительном анализе в работе [83] было выявлено, что метод ИСОМАД сумел выделить лишь 8 классов из 11 рассматриваемых, вместе с этим уступив в показателях точности методу

максимального правдоподобия (93 % против 97 %). В целом, методы кластеризации при анализе космических снимков используются значительно реже, чем контролируемые методы. При этом, можно выделить как недостатки, так и преимущества неконтролируемых алгоритмов [27]. Главным преимуществом является отсутствие необходимости в большом объеме априорной информации. Недостатками метода являются попиксельное распознавание, а также низкие оценки точности распознавания объектов на космических снимках.

Методы распознавания с контролируемым обучением используют эталонные образцы – фрагменты изображения (или отдельные пиксели), о которых имеется достоверная информация об их принадлежности к классам. При выборе таких образцов используют разнообразную справочную информацию, полученную в результате наземных полевых работ, или имеющуюся информацию об исследуемой территории в виде карт, таблиц и др. Выбор эталонных образцов является трудоемким процессом, результат которого влияет на работу всего метода интерпретации. После выбора эталонных образцов происходит расчет их векторов признаков, которые далее считают эталонами. Дальнейшее распознавание ведется на основе сравнения признаков исследуемых образцов с эталонами. Сам процесс сравнения зависит от конкретного выбранного метода распознавания.

Наиболее простым контролируемым методом классификации является метод минимального расстояния. Исходя из названия метода, следует, что принятие решения происходит на основе измерений расстояний между вектором исследуемого образца и векторами эталонов. Точнее, расстояния измеряются между вектором образца и средними векторами каждого класса, которые получают путем усреднения эталонов, принадлежащих одному классу. Вычисление расстояний между векторами может происходить в соответствии с разными мерами. Наиболее используемая мера расстояния – Евклидова. В статье [108] при классификации четырех классов объектов (реки, сельскохозяйственные земли, поселки и пустоши) методом минимального расстояния с мерой Евклида

общая точность, по оценкам авторов, составила 76 %. Этот метод получил большое применение при использовании угловой меры расстояния, расстояния Махаланобиса, Бхаттачариа, Джеффриса-Матусита. Формулы этих и других мер расстояний можно найти в литературе [78]. В работах [85, 131, 130] проведено сравнение нескольких методов классификации, в том числе метода минимального расстояния с Евклидовой мерой, с мерой Махаланобиса и Джеффриса-Матусита.

Другой широко применяемый метод распознавания – метод максимального правдоподобия (или байесовский классификатор) – основан на применении теоремы Байеса (формулы Байеса), которая утверждает, что вероятность принадлежности объекта распознавания с вектором признаков ω к классу i , определяется по формуле [20]:

$$P(i|\omega) = \frac{P(\omega|i) \cdot P(i)}{P(\omega)},$$

где $P(i)$ - априорная информация, выражающая вероятность попадания в класс i , $P(\omega|i)$ - функция правдоподобия. Вероятность того, что наблюдается вектор ω определяется по формуле:

$$P(\omega) = \sum_{i=1}^K P(\omega|i) \cdot P(i),$$

где K – количество классов. Решение о принадлежности класса принимается на основе найденной максимальной вероятности $P(i|\omega)$.

Настоящий метод во многих работах показывает высокие результаты (см., например, [82]). В работе [23] при классификации 8 классов объектов вероятности успешного распознавания классов колеблются от 42 % (для класса «сосна») до 99% (для класса «водные объекты»).

Однако, метод максимального правдоподобия основан на предположении о нормальном распределении данных. При работе с данными дистанционного

зондирования Земли нормальный закон распределения не всегда является адекватной моделью. Ещё одним недостатком метода является необходимость большого объема априорной информации.

Метод искусственных нейронных сетей (Artificial Neural Networks, ANN), обладающий множеством модификаций и вариаций, также является одним из наиболее востребованных методов [17]. Одно из главных его преимуществ состоит в отсутствии необходимости в априорной информации о статистическом распределении данных.

Базовая архитектура нейронной сети представима тремя слоями: входной, скрытый (средний), выходной. Входной слой предназначен для ввода входных данных – векторов признаков объектов, выходной для получения результата – номера класса. Скрытый слой состоит из нейронов, которые выполняют определенное преобразование. Важнейшим этапом метода является обучение, в ходе которого происходит итеративная корректировка весовых коэффициентов скрытого слоя. Особенностью метода также является то, что границы решения определяются итеративно в целях минимизации критерия ошибки [64].

Метод искусственных нейронных сетей показал свою эффективность при классификации космических снимков [120, 81, 77, 123]. Основными недостатками метода считают сложности с выбором подходящей архитектуры сети, а также большое время, необходимое для обучения метода [127].

В последнее время замечен значительный рост использования метода опорных векторов (Support Vector Machine (SVM)) при решении задач классификации изображений [128]. Этот метод основан на принципе минимизации эмпирического риска [14]. Задача состоит в том, чтобы построить оптимальную разделяющую гиперплоскость (ОРГ), которая бы верно разделила объекты по классам. Исходя из логичного предположения, что чем больше будет зазор между классами, тем более точной будет классификация, и был предложен настоящий метод. Работа метода сводится к нахождению разделяющей гиперплоскости и максимального зазора между параллельными

гиперплоскостями, которые определяются точками, лежащими в пространстве признаков ближе остальных к ОРГ и называемыми опорными векторами.

В самом простом виде метод опорных векторов представляет собой метод линейной классификации, предложенный Вапником [14]. Очевидно, что линейная разделимость для изображений дистанционного зондирования Земли является редким явлением. Для создания нелинейного метода классификации было предложено заменить скалярные произведения нелинейными функциями ядра. То есть, все образцы обучающей выборки переводятся в пространство более высокой размерности с помощью специального отображения таким образом, чтобы в новом пространстве объекты были линейно разделимы. В работе [121] дается обоснование использования некоторых SVM-ядер для классификации растительного покрова.

Большая популярность настоящего метода во многом обусловлена тем, что он позволяет получать достаточно высокие результаты при относительно небольшом объеме обучающей выборки. Это продемонстрировано, например, в работе [102]. В работе [133] подчеркивается, что метод опорных векторов менее чувствителен к так называемому явлению Хьюза [111], которое состоит в том, что при ограниченной обучающей выборке точность классификации имеет тенденцию уменьшаться по мере увеличения пространства признаков.

В целом, многие исследования показывают эффективность использования SVM [90, 129]. Однако, существуют, как исследования, в которых сравнения между методами показывают наибольшую эффективность SVM, так и такие исследования, в которых преимущества этого метода неочевидны [138]. Кроме того, некоторые авторы [127] указывают в качестве недостатков SVM существенную зависимость точности классификации от количества классов, а также трудности при выборе подходящего ядра.

Другой метод, который все чаще фигурирует в современных работах по интерпретации космических изображений – метод «случайный лес». Этот метод относится к разделу комитетных алгоритмов распознавания. Впервые был предложен Лео Брейманом [91]. Суть метода сводится к тому, что происходит

генерирование деревьев принятия решения, каждое из которых голосует за один из рассматриваемых классов объектов. Окончательное решение принимается на основании большинства голосов. К преимуществам метода относят незначительную чувствительность метода к задаваемым параметрам. Главным недостатком метода является сильная зависимость результатов от диапазона обучающих образцов. Метод «случайный лес» показал свою эффективность в ряде работ по распознаванию объектов на космических снимках (см., например, [123]). В работе [117] при классификации 10 видов деревьев на снимке высокого пространственного разрешения WorldView-2 была достигнута общая точность около 82 %.

Для оценки точности результатов классификации, сравнения результатов, выбора оптимальных параметров методов необходимо использовать объективные показатели. Оценивание точности результатов происходит по контрольной выборке, то есть, по образцам, принадлежность которых к классам известна. Наиболее часто используемой оценкой является вероятность успешной классификации или общая точность (ОТ):

$$ОТ = \frac{k}{n} \cdot 100\% , \quad (4)$$

где n – общий объем тестовой выборки, k – количество образцов, которые были отнесены к тому классу, которому они принадлежат согласно справочным данным. Такой показатель широко использовался в значительном количестве отечественных работ [1, 22]. Вероятность успешного распознавания равная 80% - 85% часто рассматривается как граница между достаточно высокой точностью и недостаточной точностью [86, 95]. В отечественной литературе базовым источником оценки вероятности распознавания является классическая работа А.Н. Живичина [22], в которой порог достаточной точности распознавания определен величиной 80 %. Однако, точность классификации зависит от множества разнообразных факторов. Например, от объема тестовой и

контрольной выборки; критериев выбора эталонных образцов; рассматриваемого набора классов и др. Поэтому принятый многими исследователями порог 80 - 85% нельзя назвать универсальным. В настоящее время для более полной оценки точности результатов рассчитывают другие показатели, которые основаны на матрице ошибок (матрице неточностей).

Матрица ошибок представляет собой массив чисел, в котором столбцы соответствуют справочной информации о тестовых образцах (то есть, сумма по столбцу равна количеству тестовых образцов рассматриваемого класса), а строки соответствуют полученным результатам классификации [95]. Таким образом, на главной диагонали матрицы ошибок представлено количество правильно распознанных образцов. Например, пусть мы исследуем три класса объектов. Тогда общий вид матрицы будет следующим:

Таблица 2 - Общий вид матрицы ошибок для трех классов объектов

	Класс 1	Класс 2	Класс 3	Сумма
Класс 1	n_{11}	n_{12}	n_{13}	n_{1*}
Класс 2	n_{21}	n_{22}	n_{23}	n_{2*}
Класс 3	n_{31}	n_{32}	n_{33}	n_{3*}
Сумма	n_{*1}	n_{*2}	n_{*3}	n

В таблице 2 n_{ij} - количество образцов i -го класса, которые в результате классификации приняты как образцы j -го класса, n_{*j} - сумма j -го столбца, n_{i*} - сумма i -й строки, n - общее количество тестовых образцов. На основе матрицы ошибок рассчитываются точности пользователя (ТП), точности разработчика (ТР) и коэффициент каппа (К) [101]:

$$ТП_i = \frac{n_{ii}}{n_{i*}}, \quad ТР_i = \frac{n_{ii}}{n_{*i}}, \quad (5)$$

$$K = \frac{n \sum_{i=1}^N n_{ii} - \sum_{i=1}^N n_{i*} n_{*i}}{n^2 - \sum_{i=1}^N n_{i*} n_{*i}}, \quad (6)$$

где N – количество рассматриваемых классов объектов. Точность пользователя и точность разработчика рассчитываются для каждого класса. При этом точность разработчика класса i представляет собой долю правильно распознанных объектов в классе i , а точность пользователя класса i рассчитывается как отношение правильно распознанных образцов этого класса к общему количеству образцов, которые в результате классификации были отнесены к классу i . Точности пользователя и разработчика соответствуют вероятностям не совершения ошибок первого и второго рода при проверке статистических гипотез [33]. Ошибки первого и второго рода в литературе по ДЗЗ иногда называют ошибками приписки и ошибками пропуска, соответственно [39]. Но такие показатели, также как и вероятность успешного распознавания, не учитывают, что некоторые образцы могут быть классифицированы в правильный класс случайно [95]. В связи с этим для оценки точности классификации часто используют коэффициент каппа Коэна [96], который некоторые исследователи призывают считать стандартным способом оценки точности [137]. Действительно, этот коэффициент обладает рядом преимуществ. Например, он позволяет сравнивать матрицы ошибок, построенные для разных методов классификации и для классификаций, проведенных в отличающихся условиях (например, объем контрольной и обучающей выборки). Некоторые исследователи также рекомендуют перед расчетом коэффициента каппа проводить нормализацию матриц [95].

Таким образом, для создания полной картины точности результатов классификации, необходимо рассчитывать и анализировать все рассмотренные показатели (4) - (6).

1.5. Сравнительный анализ известных реализаций систем интерпретации изображений площадных объектов местности

Был проведен анализ научных статей за период с 2004 по 2015 год по тематике классификации многозональных изображений. Данные статей сведены в таблицу, представленную в приложении А.

Сравнительный анализ позволил сделать следующие выводы.

1. Спектральные признаки повсеместно и достаточно эффективно используются для обработки снимков с низким разрешением (30 м и более). На таких изображениях не разрешается структура анализируемых классов растительности (например, различные с/х культуры), и задача распознавания решается только для однородных по составу классов, чьи спектральные характеристики имеют значимые различия.

2. При исследовании изображений высокого (1-6 м) и сверхвысокого (1 м менее) разрешения спектральные признаки способны обеспечивать высокую точность классификации, но в условиях рассмотрения однородных по составу классов объектов, либо при рассмотрении неоднородных классов объектов, но существенно визуально отличающихся между собой, что сужает круг решаемых задач.

3. Работы с использованием только текстурных признаков для изображений земной поверхности практически не встречаются, что, по-видимому, объясняется тем, что отсутствие спектральной информации не позволяет решать сложные задачи дифференцирования классов растительности.

4. Совместное использование спектральных и текстурных признаков позволяет получать высокие точности классификации для множества объектов, структура которых разрешается на снимке. При этом классы объектов могут быть как однородными по составу, так и неоднородными.

5. Задача распознавания классов объектов неоднородных по составу со структурой, которая разрешается на снимке, решается только комбинированием информации о спектральных и структурных свойствах изображения. То есть,

система признаков в этом случае должна состоять либо из достаточно полного комплекса спектральных и текстурных признаков, либо строиться на основе вейвлет-анализа мультиспектральных данных. Рассмотрение классов объектов неоднородных по составу и представленных изображениями с разрешаемой структурой с использованием такой схемы построения признаков позволяет решать задачи дифференцированного определения характеристик этих объектов. Например, определение возраста деревьев, диаметра крон и т.п. Подобными трудными для решения задачами в настоящее время являются задачи определения областей местности с характерными свойствами, то есть областей, отличающихся от окружения по структуре изображения и спектральным свойствам, что обусловлено различием условий формирования растительности.

6. В большей части работ используются и предлагаются контролируемые методы классификации. Использование неконтролируемых методов, как правило, подразумевает попиксельную классификацию и рассмотрение узкого круга классов объектов однородных по составу, чья структура не разрешается на снимке. Исследования, посвящённые сравнительному анализу методов принятия решения с этапом обучения и без него, подтверждают большую эффективность контролируемых методов классификации.

7. В ряде работ подчеркивается, что процедура выбора наиболее информативных признаков является эффективным средством улучшения качества классификации. Поэтому целесообразно использовать метод классификации, включающий в себя этап оценки информативности признаков и уменьшения на основе этой оценки признакового пространства.

В результате анализа современных публикаций по тематике дешифрирования снимков можно сделать следующий общий вывод. В большей части работ используются спектральные признаки в виде значений яркостей пикселей в разных каналах изображений, а также вегетационных индексов. Почти полностью отсутствуют работы, использующие только структурные признаки для интерпретации мультиспектральных данных. Часть работ использует комбинированные системы признаков, сочетающие в себе и спектральную, и

структурную информацию. В последнее время значительное место занимают работы, которые в качестве признаков применяют характеристики, вычисляемые на основе вейвлет-преобразования, что позволяет представлять как частотную, так и пространственную информацию. В ряде работ подчеркивается важность применения процедуры отбора наиболее информативных признаков, а также преимущества контролируемых методов классификации.

Пространственная структура изображений объектов местности носит составной, изменчивый и регулярно-стохастический характер, что усложняет задачу распознавания. Кроме того, регистрация изображения на пороге линейного разрешения затрудняет визуальное восприятие. Существующие методы анализа изображений с размерами деталей на пороге и ниже разрешающей способности снимка не удовлетворяет требованиям высокой надежности распознавания. Вместе с тем, современное развитие съемочных систем дает возможность получения снимков высокого пространственного и спектрального разрешения, что позволяет ставить и решать новые задачи, для которых необходимы новые методы. Объекты, которые было невозможно распознать на снимках прошлых лет, становятся различимыми на современных снимках. Поэтому необходимо создавать и использовать новые методы компьютерной обработки изображений.

1.6. Выводы по Главе 1

1. Проведен анализ существующих и перспективных систем признаков и методов классификации при решении задач распознавания многозональных изображений объектов лесной растительности.

2. Выявлено, что для работы со снимками высокого пространственного и спектрального разрешения необходимо разработать систему признаков, учитывающую как спектральные, так и пространственные особенности (включая пространственные и частотные свойства) данных, и позволяющую распознавать трудноразличимые объекты с приемлемой точностью. Перспективным способом

формирования такой системы признаков является применение вейвлет-преобразования в различных каналах многозональной съемки.

3. Установлено, что для повышения качества классификации необходимо проводить отбор наиболее значимых признаков, позволяющих формировать полное и достоверное описание изображенного объекта.

4. Для распознавания трудноразличимых изображений объектов местности необходимо разработать контролируемый метод классификации, который должен быть адаптирован к работе с разными признаками (дискретными, непрерывными), а также обладать схемой оценивания информативности признаков и уменьшения признакового пространства.

Глава 2. Метод интерпретации данных дистанционного зондирования в задаче классификации лесной растительности

2.1. Системный анализ задачи интерпретации космических снимков площадных объектов местности

Задача интерпретации космических снимков, её сложность, пути её решения, во многом, определяются свойствами изображения. Космические многозональные изображения являются результатом взаимодействия объектов местности со съёмочной системой (взаимодействие не является контактным: съёмочная система фиксирует отражённый солнечный свет от объектов местности). Поэтому свойства интерпретируемого изображения зависят от свойств объектов местности, свойств съёмочной системы и условий съёмки. Системный анализ перечисленных факторов в сочетании с учетом требований к результатам решения задачи интерпретации изображений объектов позволит определить актуальные направления разработки методов интерпретации. Схема системных связей процесса формирования изображения объектов местности при дистанционном зондировании продемонстрирована на рисунке 4.

Рассмотрим характеристики качества снимков. Для получения изображения объектов местности используются специальные съёмочные системы, которые могут быть установлены как на искусственные спутники Земли, так и на низколетящие беспилотные или другие летательные аппараты. Качество получаемых изображений определяется разрешением снимка, а также искажениями, возникающими в процессе съёмки. Данные ДЗЗ характеризуются пространственным, спектральным и радиометрическим разрешением.

Под пространственным разрешением понимается «размер на местности самой малой детали, воспроизведенной на снимке» [39]. При рассмотрении задач картографирования и распознавания площадных объектов местности, используют, как правило, снимки среднего разрешения (6-10 м), высокого (1-6 м) и сверхвысокого разрешения (менее 1 м). От пространственного разрешения снимка

зависит различимость деталей на изображении, что влияет на круг возможных решаемых задач, а также на наличие и характеристики текстуры изображения.

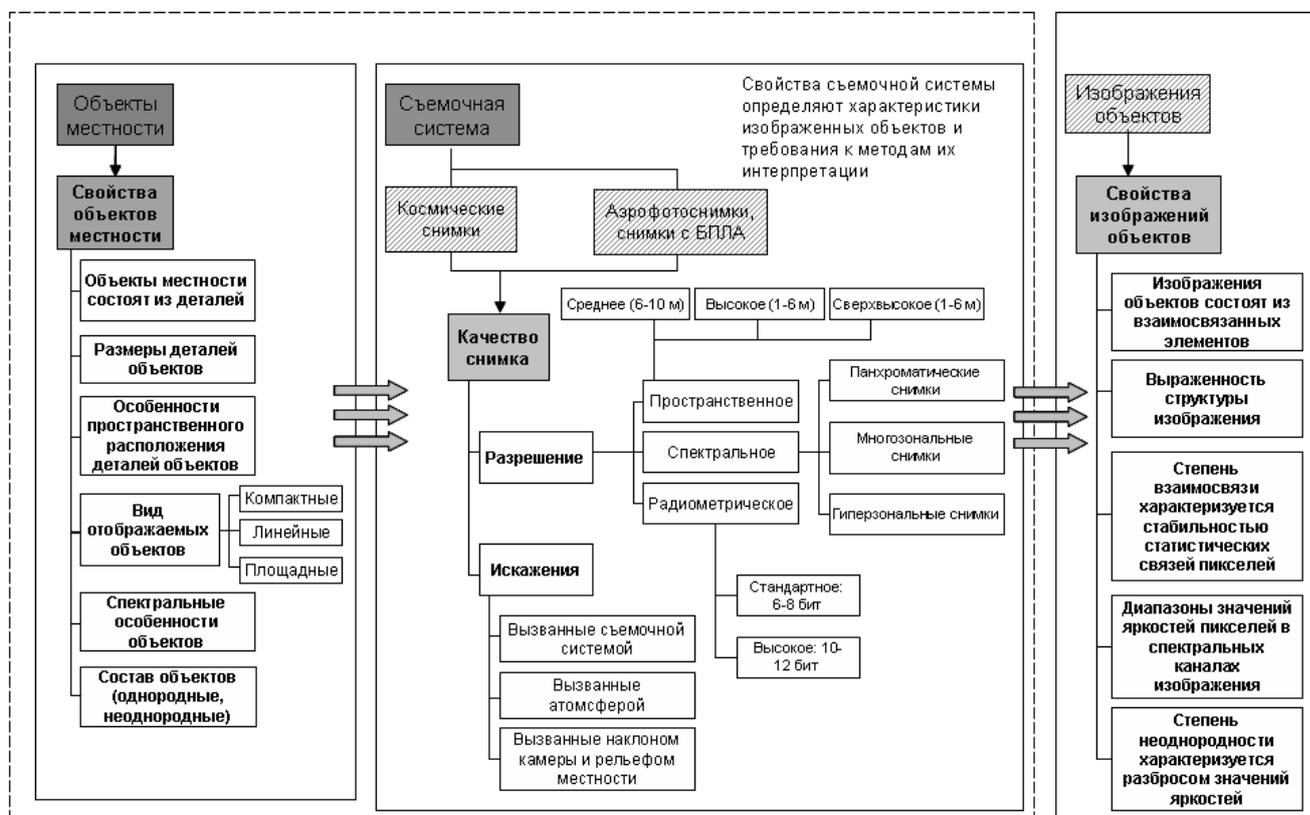


Рисунок 4 - Схема системных связей процесса формирования изображения объектов местности при дистанционном зондировании

Ширина спектрального канала определяет спектральное разрешение данных ДЗЗ. В зависимости от спектрального разрешения выделяют панхроматические (1 широкий спектральный канал), многозональные (3-15 каналов) и гиперзональные изображения (сотни узких спектральных каналов). Высокое спектральное разрешение снимка расширяет возможности его применения.

Радиометрическое разрешение определяется количеством уровней дискретизации яркостей солнечного излучения, отраженного объектом. Большинство снимков поставляются со стандартным разрешением в 6-8 бит на пиксель, однако, существуют снимки с радиометрическим разрешением в 10-12 бит на пиксель.

При дистанционном зондировании Земли из космоса в процессе прохождения отобранного объектами светового потока по каналу, состоящему из атмосферы и оптико-съёмочной системы сканера, возможны искажения, возникающие по разным причинам, главными из которых являются: свойства атмосферы, через которую проходит отражённый солнечный свет; оптические измерительные характеристики съёмочной системы; рельеф местности и наклон камеры.

Съёмочная аппаратура, фиксируя отражённый солнечный свет от объектов на поверхности земли, формирует изображение, свойства которого не могут не зависеть от самих объектов, изображённых на нём. Рассмотрим свойства объектов местности, которые оказывают влияние на формирование изображения.

Прежде всего, все объекты местности состоят из деталей. Например, деталями лесов являются отдельные деревья, деталями городских застроек выступают дома и т.д. На изображении детали объекта выражаются элементами изображения объекта, которыми могут выступать как отдельные пиксели, так и их компактные группы. От размеров деталей объектов местности, а также от пространственного разрешения снимка, зависит различимость структуры изображения.

Все объекты местности характеризуются своей пространственной структурой, которая определяется размерами и формой объекта и составляющих его элементов, а также характером их пространственного размещения. На характер пространственного размещения элементов структуры оказывает влияние тип объекта местности (компактные, линейные и площадные объекты [65]).

Поскольку детали объектов местности на снимке представляются пикселями или компактными группами пикселей, то особенности пространственного расположения деталей объектов на изображении характеризуются стабильностью статистических связей пикселей.

Многозональная съёмка позволяет отражать на мультиспектральных снимках уникальные особенности объектов на поверхности Земли. Объекты разной природы или, например, объекты в разных фенологических состояниях по-

разному отражают солнечный свет. Так, согласно рисунку 5 [125], отраженное солнечное излучение в видимом диапазоне электромагнитного спектра от деревьев с желтеющей листвой примерно в 4 раза больше, чем от деревьев с зеленой листвой. Таким образом, мультиспектральные изображения могут нести в себе довольно много полезной информации, характеризующей свойства объектов местности.

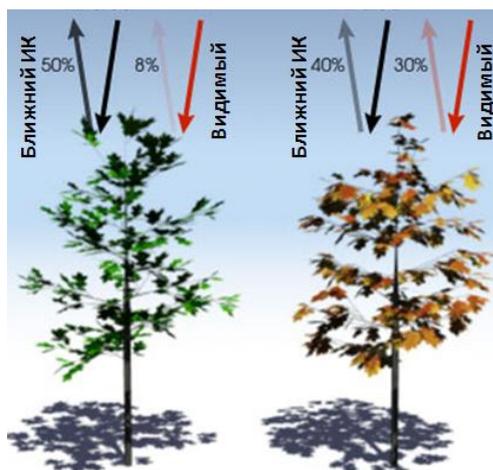


Рисунок 5 - Иллюстрация различий в отражающей способности деревьев с зелёной и жёлтой листвой

На изображении спектральные особенности объектов выражаются значениями яркостей пикселей в различных спектральных каналах. Иллюстрацией этого служат спектральные кривые, которые представляют собой графики зависимости значений пикселей от канала изображения (или длины волны).

На спектральные особенности объектов влияет масса факторов, среди которых, например, фенологическое состояние растительности, однородность объектов по составу и др. Однородность или неоднородность объектов по составу свойственна в первую очередь для площадных объектов, таких как леса. Например, объект "еловый лес" является однородным по составу, а "смешанный лес" – неоднороден по составу. Распознавание классов объектов, которые неоднородны по составу, является более сложной задачей, поскольку для таких

объектов наблюдается значительный разброс в значениях спектральных признаков и большая неоднородность яркостей элементов изображения.

Постановка задачи интерпретации изображений и методы её решения в значительной степени зависят от характеристик снимка. На рисунке 6 представлена схема зависимости выбора метода решения задачи интерпретации от пространственного и спектрального разрешений снимка.

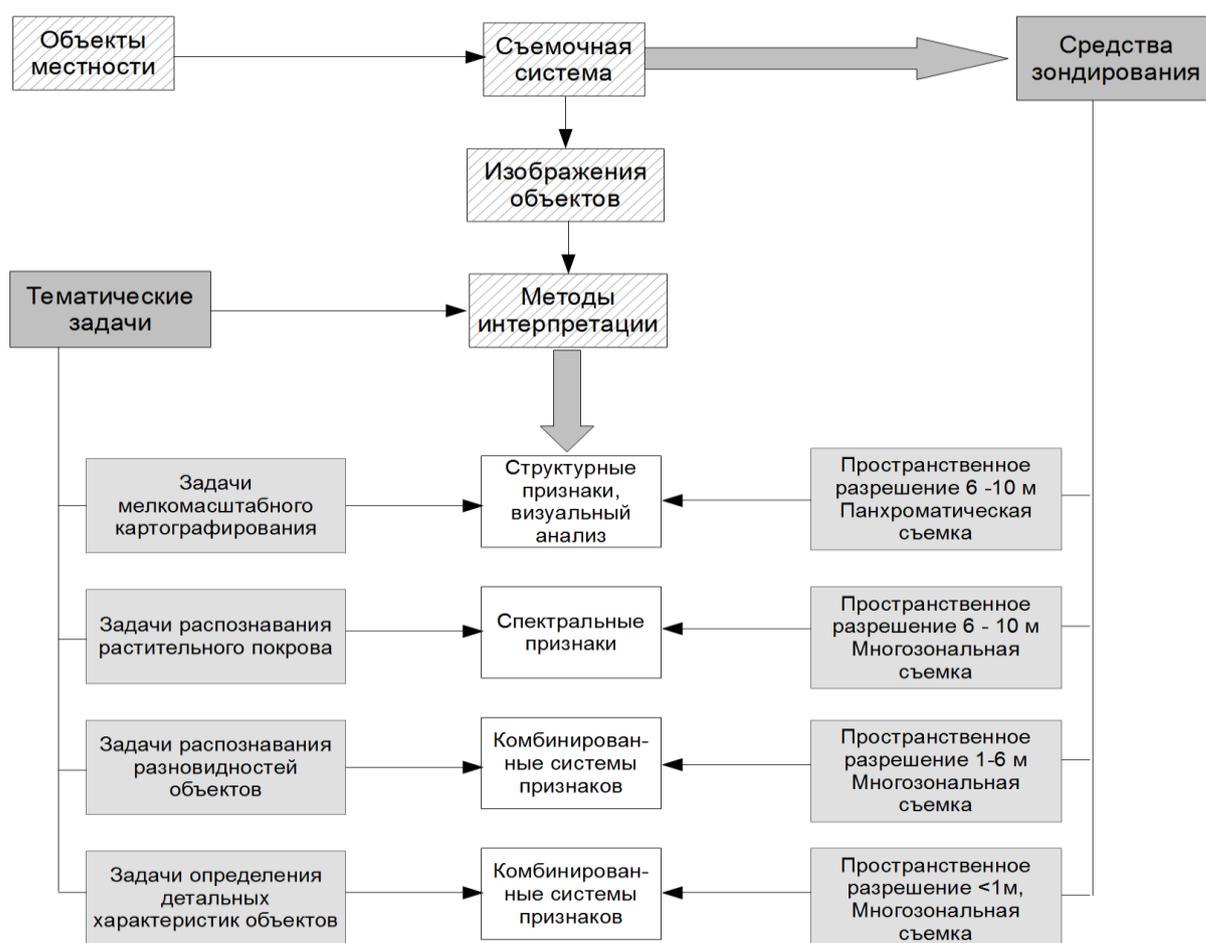


Рисунок 6 - Методы анализа данных дистанционного зондирования площадных объектов растительности

Материалы современной съемки с более высоким пространственным разрешением позволяют ставить новые задачи, решение которых было невозможным при работе со снимками более низкого разрешения. При работе со снимками, разрешение которых хуже 6 м, как правило, решаются задачи

мелкомасштабного картографирования. На таких снимках хорошо видны города, леса, поля и др. крупные объекты. Если такой снимок не является многозональным, либо количество каналов не превышает 4, то эффективным методом интерпретации может служить визуальный анализ. Если такой снимок является многозональным, как минимум с 5 каналами, то возможно эффективное распознавание растительных покровов земли с частичным решением задачи определения разновидностей при использовании спектральных методов классификации.

Используя снимки с пространственным разрешением в 1 - 6 м., становится возможным решение задач распознавания разновидностей объектов, чьи детали имеют размеры на границе разрешения снимка (разновидности лесов). Многозональность таких снимков в разы увеличивает надежность классификации. В этом случае решение задачи с высокой точностью возможно при использовании комбинированной системы признаков, включающей в себя и структурные, и спектральные характеристики.

Снимки сверхвысокого разрешения (менее 1 м) изображения позволяют решать задачи определения детальных характеристик объектов также при использовании комбинированной системы признаков.

Задача интерпретации площадных объектов местности по космическим снимкам, рассмотренная в настоящей работе, входит в класс задач распознавания разновидностей объектов по снимкам высокого разрешения. При её решении необходимо согласовано рассматривать свойства исследуемых объектов и качество снимка. Схема системного анализа рассматриваемой задачи представлена на рисунке 7.

Все рассматриваемые далее в настоящей работе объекты местности являются площадными. Снимки, на которых проводится исследование, имеют следующие характеристики: пространственное разрешение – от 1 м (БПЛА) до 5 м (RapidEye); спектральное – от 5 каналов (RapidEye) до 7 каналов (QuickBird); радиометрическое – от 8 (БПЛА) до 12 бит на пиксель (RapidEye).

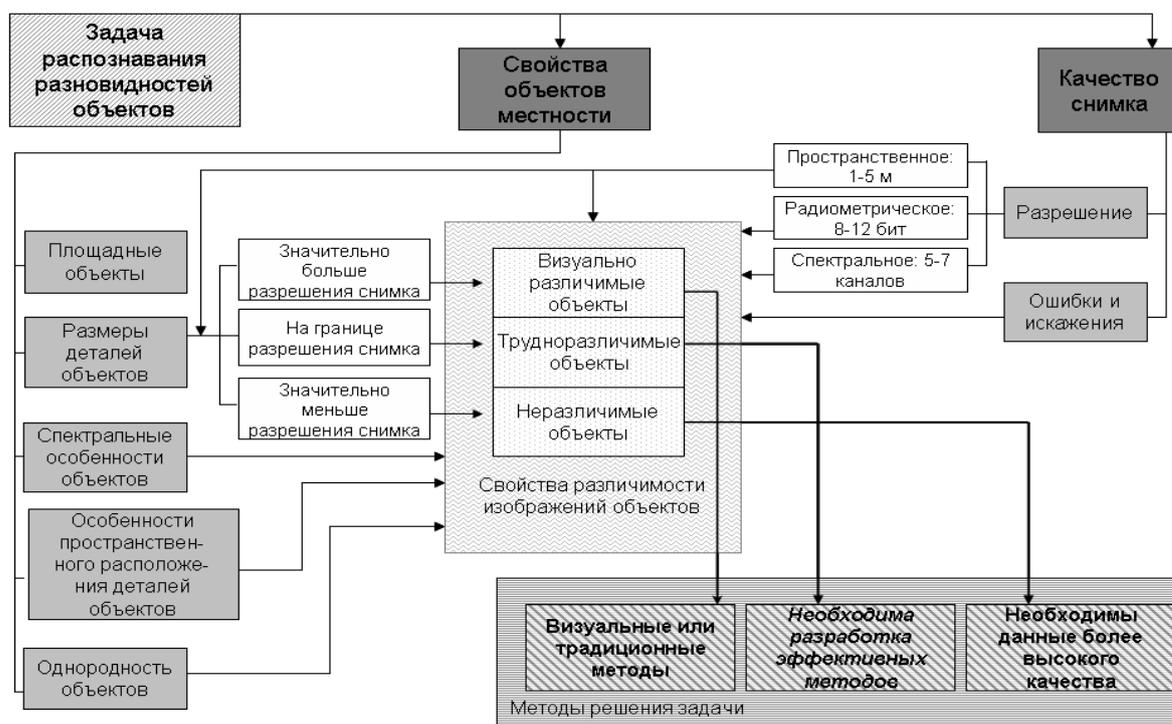


Рисунок 7 - Системный анализ задачи распознавания разновидностей площадных объектов

В зависимости от размеров деталей объектов и пространственного разрешения снимка возникают свойства различимости изображений объектов. Согласно этим свойствам все объекты на снимке можно разбить на три группы: визуально различимые, трудно различимые (см. п.1.1) и неразличимые объекты. Понятие трудно различимых объектов на снимке было введено А.Н. Живичиным [22], согласно которому вероятность распознавания P объекта на изображении определяется зависимостью (1).

На рисунке 8 представлена диаграмма областей различимости объектов. Когда разрешение снимка ниже, чем минимальный размер рассматриваемого объекта, то объект на таком снимке неразличим. Если размер объекта сопоставим с разрешением снимка, то объект называют трудно различимым. В случае если разрешение снимка, как минимум, в 3 раза выше, чем размер объекта, то исследуемый объект визуально различим на снимке.

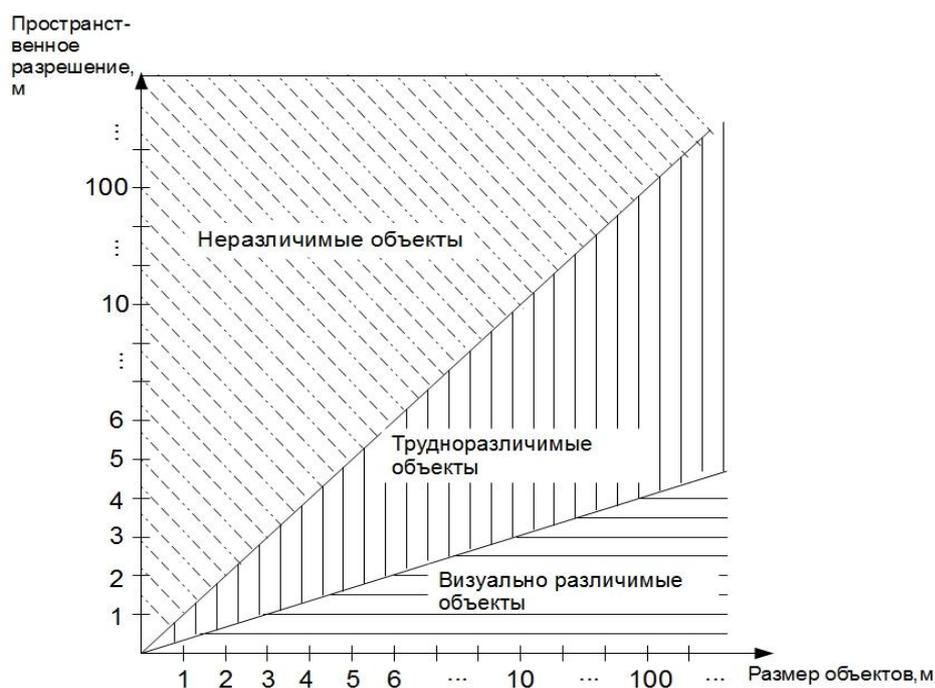


Рисунок 8 - Диаграмма областей различимости объектов на снимке

В зависимости от того насколько различим исследуемый объект на снимке, а также от ряда других свойств объектов местности и характеристик снимка выбирается метод распознавания. При рассмотрении визуально различимых объектов эффективно применяются визуальные методы анализа, а также традиционные методы распознавания (классификатор минимального расстояния, максимального правдоподобия и др.). При распознавании трудно различимых на снимке объектов существующие методы не позволяют получать результаты с высокой точностью распознавания, поэтому необходимы новые методы для решения этой задачи. В случае исследования объектов, которые на снимке неразличимы, следует рассмотреть возможность их исследования на снимке более высокого пространственного и спектрального разрешения.

Для решения задачи распознавания площадных объектов местности, в том числе лесов, относящихся к трудно различимым объектам, на снимках высокого разрешения необходимы новые методы, основанные на использовании сочетания спектральной и структурной информации изображения.

Таким образом, можно сделать выводы: качество результатов интерпретации космических снимков земной поверхности зависит от свойств

объектов местности, характеристик съемочной системы и условий съемки; особый класс изображений объектов местности составляют трудноразличимые объекты, к которым относятся объекты с размерами деталей на пороге разрешения снимка; для трудноразличимых объектов существующие методы распознавания данных ДЗЗ недостаточно эффективны, необходима разработка новых эффективных методов.

2.2. Вейвлет-преобразование как основа определения признаков изображения

В результате системного анализа задачи распознавания площадных объектов местности выявлено, что для решения поставленной задачи необходимо разработать систему признаков, сочетающую в себе разнородную информацию. С этой точки зрения, наиболее перспективным направлением является применение вейвлет-преобразования изображений, позволяющего описывать сигнал и в пространственной, и в частотной областях. А вейвлет-преобразование многозональных снимков позволяет учесть спектральную информацию.

Непрерывное вейвлет-преобразование описывается формулой [34]:

$$W(s, t_0) = \int_{-\infty}^{+\infty} f(t) \psi_{s, t_0}(t) dt,$$

где s – коэффициент масштабирования, t_0 – сдвиг, $f(t)$ – исследуемый сигнал, $\psi_{s, t_0}(t)$ – вейвлетная функция, которая получается из материнского вейвлета $\psi_0(t)$ путем сдвига на t_0 и масштабирования с коэффициентом s . Материнская вейвлет-функция должна удовлетворять некоторым условиям [19], основные из которых: функция должна быть локализована и в пространственной, и в частотной областях; среднее значение должно быть нулевым, т.е. $\int_{-\infty}^{+\infty} \psi_0(t) dt = 0$.

Таким образом, материнская вейвлет-функция «хорошо локализована в пространстве и быстро стремится к нулю» [34]. За счет сдвигов материнской

вейвлет-функции, покрывается вся область, на которой определен исходный сигнал. Таким образом, любую функцию из гильбертова пространства $L^2(R)$ можно разложить на некотором заданном уровне разрешения j_n в ряд вида [19]:

$$f(t) = \sum_k a_{j_n,k} \varphi_{j_n,k} + \sum_{j \geq j_n,k} d_{j,k} \psi_{j,k}, \quad (7)$$

где $\varphi_{j_n,k}$ - масштабирующая (скейлинг) функция, $a_{j_n,k}$ - коэффициенты, соответствующие аппроксимации, $d_{j,k}$ - коэффициенты деталей. Первую сумму в (7) называют основным потоком, а вторую – вейвлетным. Поэтому можно говорить о связи вейвлет-разложения с низкочастотными и высокочастотными фильтрами. Низкочастотные фильтры выделяют главную тенденцию сигнала, подавляя при этом высокочастотные составляющие. В то время как высокочастотные фильтры, напротив, выделяют разницу между исходным сигналом и основной тенденцией.

В определенном смысле, вейвлет-преобразование можно считать развитием оконного преобразования Фурье. Как известно, Фурье-преобразование является мощным инструментом анализа сигналов, который позволяет определять наиболее характерные частоты. Основная особенность, а также преимущество вейвлет-преобразования, состоит в его способности описывать исходный сигнал, как в частотной, так и в пространственной области, в то время как Фурье-преобразование характеризует только частотную составляющую. Для изображений с разрешаемой структурой (см. п.1.1) эта особенность вейвлет-преобразования является определяющей. Как показал обзор существующих работ, а также системный анализ, приведенный в п.2.1, высокая точность классификации многозональных изображений объектов с разрешаемой структурой может быть получена при комбинировании пространственной и частотной информации.

В случае с обработкой изображений, необходимо применять двумерное дискретное вейвлет-преобразование (ДВП). Стандартным способом двумерного

ДВП является схема преобразования Малла [124]. Схема быстрого преобразования Малла, приведенная на рисунке 9, сводится к последовательному применению фильтров высоких (ФВЧ) и низких частот (ФНЧ) к строкам и столбцам изображения. Фильтрами низких и высоких частот выступают масштабирующая функция и вейвлет-функция, которые в дискретном случае выражаются набором коэффициентов. Таким образом, разложение сигнала на две составляющие – общая тенденция и отклонения – представляет собой применение квадратурных зеркальных фильтров (QMF) [106].

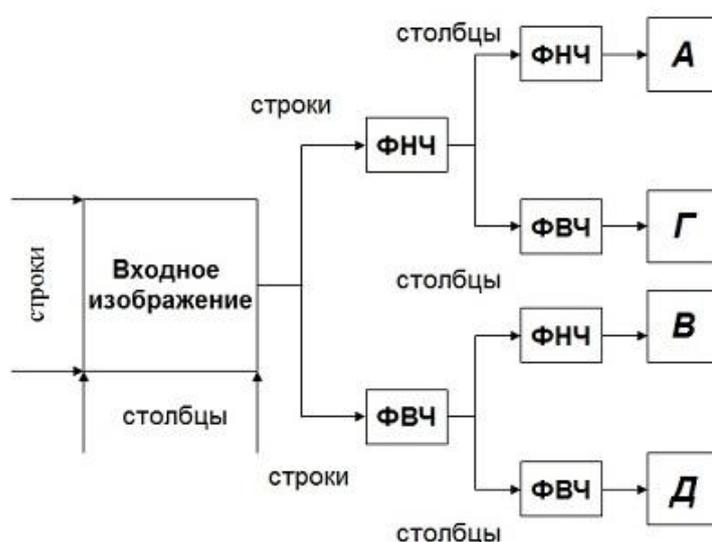


Рисунок 9 - Стандартная схема Малла двумерного ДВП

В результате двумерного ДВП получают 4 изображения: А – аппроксимация исходного изображения, получаемая в результате двукратного применения ФНЧ; Г, В, Д – изображения, на которых более отчетливо выделены соответственно горизонтальные, вертикальные и диагональные детали. Пространственное расположение изображений ДВП представлено на рисунке 10(а). При этом размеры полученных изображений ДВП уменьшаются в 2 раза по отношению к исходному фрагменту. Описанная процедура представляет собой первый уровень ДВП. Часто применяют процедуру, позволяющую проводить ДВП более высоких уровней. Для этого в качестве основы последующих преобразований используют изображение аппроксимации А и проделывают с ним ту же операцию, что и с

исходным изображением на 1 уровне. Таким образом, можно получать все более высокие уровни преобразования. Этот процесс схематически отображен на рисунке 10(б). Такую процедуру, которая позволяет посмотреть на исходное изображение в нескольких масштабах, называют кратномасштабным анализом [19]. С точки зрения распознавания объектов на снимке, рассмотрение результатов нескольких уровней ДВП может позволить получить больший объем полезной информации. В нашем случае, когда для классификации представлены объекты лесной растительности, которые на изображениях имеют достаточно сложную структуру, количество уровней преобразования имеет важное значение и требует дополнительного исследования.

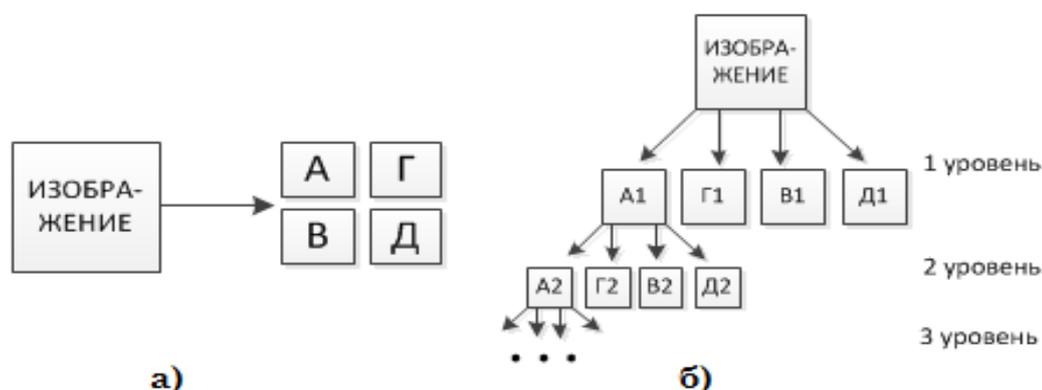


Рисунок 10 – Особенности двумерного ДВП: а) пространственное расположение изображений ДВП; б) схематическое представление вейвлет-разложения изображения

При анализе изображений также нередко используют вейвлет-пакеты, которые раскладывают на 4 изображения ДВП не только изображения аппроксимации (А), но изображения деталей (Г, В, Д) [68]. Схематическое разложение изображения вейвлет-пакетом на 2 уровня ДВП представлено на рисунке 11.

В силу того, что в результате применения одного уровня ДВП по схеме Малла, изображение аппроксимации уменьшается в размерах в 2 раза, то нередко

этот вид преобразования изображают в виде пирамиды [106], представленной на рисунке 12(а).

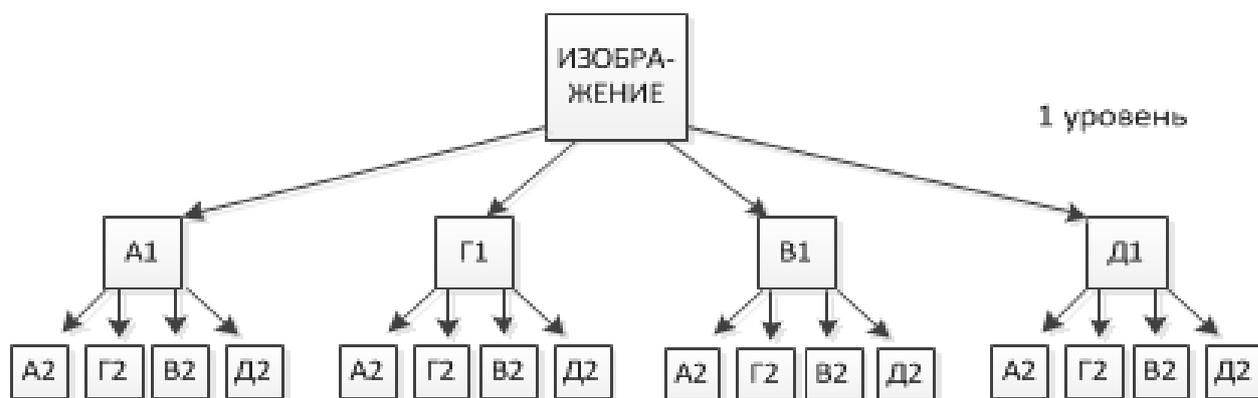


Рисунок 11 - Схематическое представление разложения вейвлет-пакетом

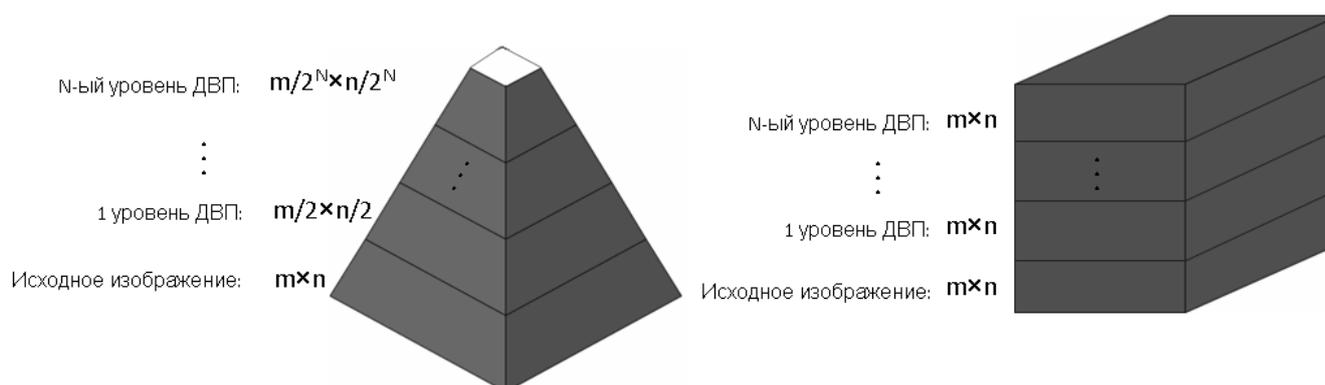


Рисунок 12 – Иллюстрация результата двумерного ДВП а) по алгоритму Малла; б) по алгоритму a'trous

Кроме стандартной схемы двумерного дискретного вейвлет-преобразования, предложенной Малла, существует другой способ проведения ДВП, который носит название a'trous (пер. с франц.: отверстия) [110]. В отличие от метода Малла, a'trous не является ортогональным преобразованием и позволяет проводить ДВП, которое инвариантно относительно сдвига. На каждом уровне ДВП получаемые изображения аппроксимации имеют всё более низкое пространственное разрешение, но размеры изображений не изменяются, что отображено на рисунке 12(б), где результаты преобразования представимы параллелепипедом. Так, разрешение аппроксимирующего изображения ДВП на

уровне N будет составлять 2^{j-N} (где 2^j – разрешение исходного изображения). Детализирующим изображением в таком преобразовании выступает изображение вейвлет-коэффициентов, которое получают путём вычитания изображения аппроксимации уровня $K+1$ из изображения аппроксимации уровня K . Оно обобщает горизонтальные, вертикальные и диагональные детали.

Поскольку при исследовании лесной растительности по космическим изображениям, отдельные коэффициенты горизонтальных, вертикальных и диагональных деталей могут обладать существенной различительной способностью, то для проведения ДВП в настоящей работе был выбран алгоритм, предложенный Малла.

Исходное многозональное изображение представляет собой трехмерный массив пикселей P , две первые размерности которого (x, y) характеризуют расположение пикселя в плоскости xOy , а третья определяет спектральный канал изображения. Процедура ДВП применяется к каждому отдельному каналу многозонального изображения, поэтому результирующие изображения ДВП также являются многозональными. Для формирования системы признаков рассчитываются численные показатели по полученным изображениям ДВП в каждом канале мультиспектральных данных. В качестве таких показателей в настоящей работе предложено использовать средние значения (8) и стандартные отклонения (9), рассчитанные по всем каналам всех изображений ДВП.

$$m = \frac{1}{n} \sum_{i=1}^n p_i, \quad (8)$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (p_i - m)^2}, \quad (9)$$

где n – общее количество пикселей образца, p_i – значение i -го пикселя.

Как уже отмечалось, вейвлет-преобразование на более высоких уровнях преобразования способно извлекать дополнительную информацию полезную для распознавания объектов на снимке, поэтому целесообразно исследовать систему

признаков из показателей (8), (9), вычисленных по изображениям ДВП нескольких уровней. ДВП на более высоких уровнях дает изображения, разрешение которых в 2 раза меньше по сравнению с изображениями на предыдущем уровне. Вычисление таких характеристик по окнам размера 2×2 и 4×4 не является целесообразным, поэтому при проведении N-уровневого ДВП необходимо учитывать размеры исходных фрагментов изображения.

Средние значения (8) и стандартные отклонения (9), рассчитанные по изображениям ДВП в разных каналах, характеризуют одновременно спектральную, частотную и пространственную составляющую. Исследование системы признаков, сформированной из (8) и (9), приводится в п. 3.1.

В результате системного анализа, было выявлено, что для площадных объектов, состоящих из трудноразличимых деталей, особенно важно рассматривать структурные характеристики. Для этого были исследованы бинарные массивы изображений, полученные по следующему правилу: элемент массива с индексами i, j равен единице, если соответствующий этому элементу пиксель p_{ij} превышает заданный порог, иначе элементу присваивается ноль. Примеры бинарных массивов для текстурных изображений из альбома Бродаца приведены на рисунке 13. Анализ полученных изображений позволил сделать вывод о том, что изображения объектов, имеющих отличную друг от друга структуру, проявляют эти отличия и в бинарных массивах, которые строятся по полученным изображениям ДВП. На основании этого были предложены признаки, характеризующие особенности таких бинарных массивов с отсечением по заданному порогу. В состав признаков входят: количество пикселей, превышающих заданный порог; количество пиков, площади пиков и др.

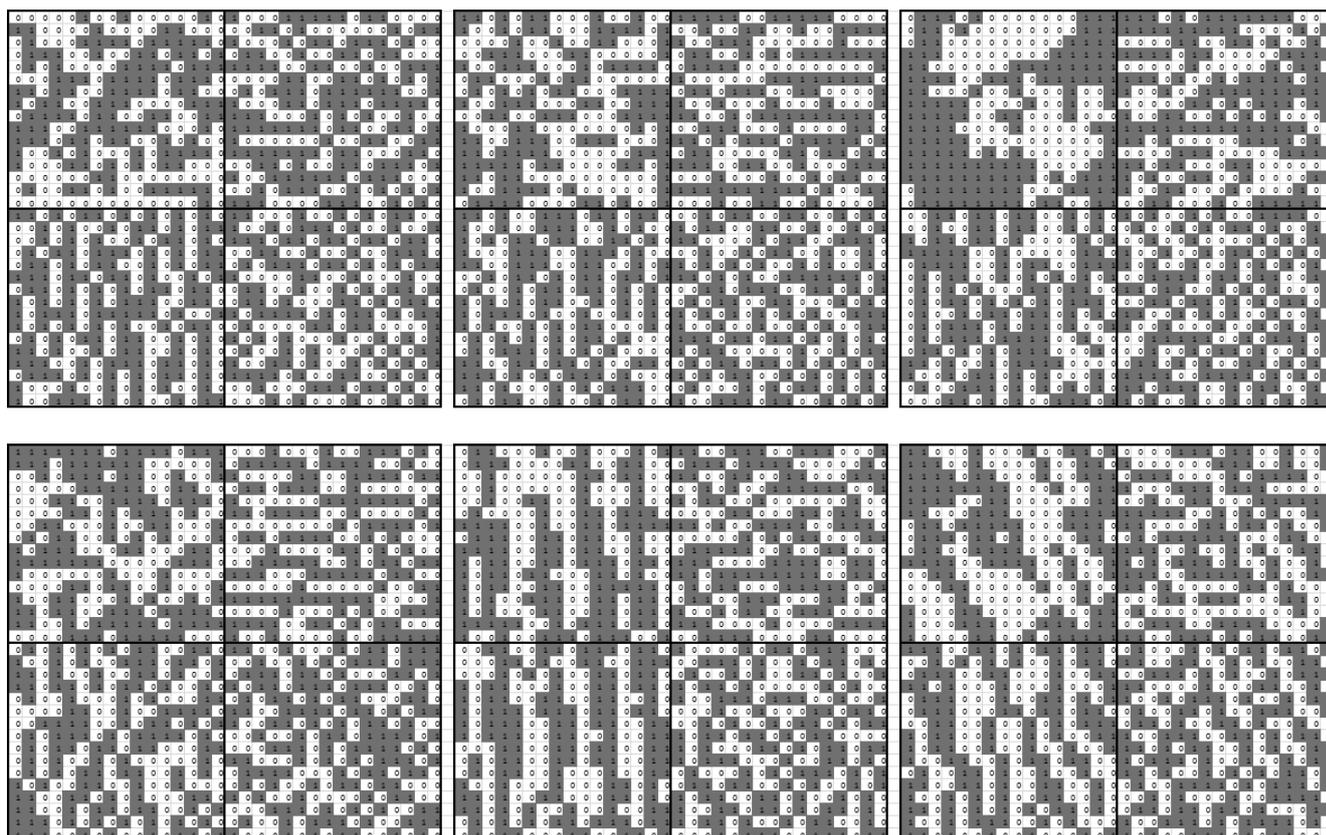


Рисунок 13 - Примеры бинарных массивов, полученных для образцов изображений из альбома Бродаца, где серым цветом выделены ячейки со значением 1

Одним из главных вопросов при проведении ДВП является выбор вейвлет-функции. В настоящей работе исследуется несколько вейвлет-функций, выбор которых был основан на опубликованных исследованиях [100, 93].

Вейвлет Хаара является одним из самых простых и первых вейвлет-функций. Он хорошо локализован в пространственной области, однако имеет широкий частотный спектр. Вейвлет Хаара аналитически задаётся следующей формулой:

$$\psi(x) = \begin{cases} 1, & x \in [0, 1/2) \\ -1, & x \in [1/2, 1) \\ 0, & x \notin [0, 1) \end{cases}$$

Соответствующая масштабирующая функция Хаара имеет вид прямоугольной волны и задаётся формулой:

$$\varphi(x) = \begin{cases} 1, & x \in [0,1) \\ 0, & x \notin [0,1) \end{cases}$$

Их графическое представление проиллюстрировано на рисунке 14.

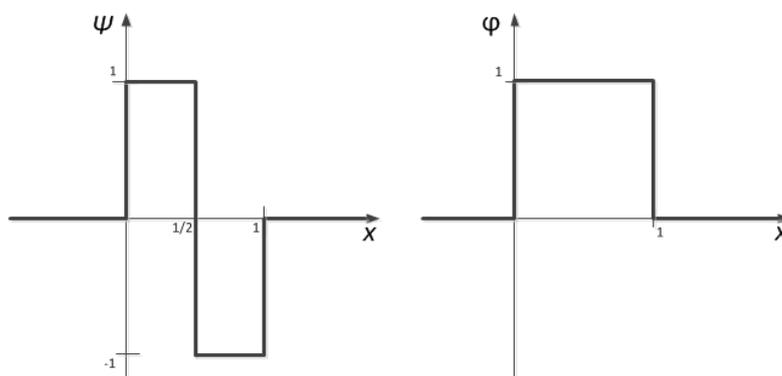


Рисунок 14 - Материнская вейвлет функция Хаара (слева) и масштабирующая функция (скейлинг-функция) Хаара (справа)

Вейвлет Хаара обладает рядом недостатков, что сильно ограничивает использование данной функции. В частности, вейвлет Хаара имеет разрывы, что нежелательно при анализе гладких функций, а также плохо локализован в частотной области. С целью найти более гладкие функции, обладающие компактным носителем, были предложены вейвлеты Добеши.

Количество нулевых моментов вейвлетов Добеши зависит от порядка выбранной вейвлет-функции. В настоящей работе исследовался вейвлет Добеши второго порядка, который описывается 4 коэффициентами $d(10)$, а вид материнской вейвлет-функции и соответствующей скейлинг-функции представлены на рисунке 15.

$$d_1 = \frac{1+\sqrt{3}}{4\sqrt{2}}, d_2 = \frac{3+\sqrt{3}}{4\sqrt{2}}, d_3 = \frac{3-\sqrt{3}}{4\sqrt{2}}, d_4 = \frac{1-\sqrt{3}}{4\sqrt{2}} \quad (10)$$

Вейвлет Добеши должен хорошо описывать изображения, обладающие выраженной структурой, поскольку функции этого семейства имеют компактный носитель и являются более гладкими в сравнении с вейвлетом Хаара.

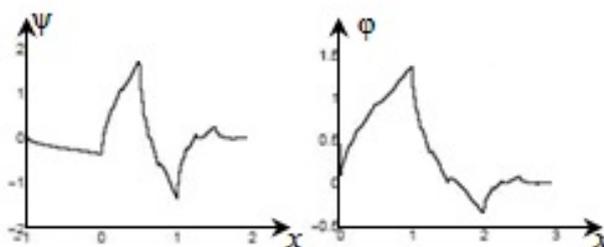


Рисунок 15 - Материнская вейвлет-функция D-4Добеши (слева) и соответствующая ей масштабирующая функция (справа)

Для многих приложений желательным свойством вейвлетов выступает равенство нулю нескольких моментов соответствующих масштабирующих (скейлинг) функций [58]. В связи с этим в вейвлет-анализ были введены койфлеты. У койфлетов нулевой момент имеет не только вейвлет-функция, но и масштабирующая функция. График койфлета первого порядка и его масштабирующая функция представлены на рисунке 16.

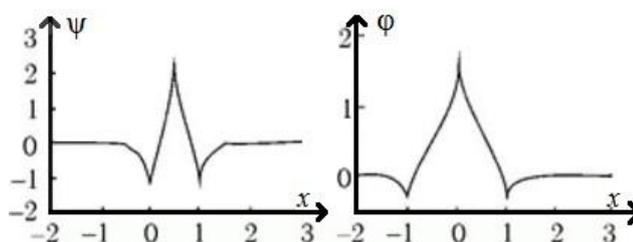


Рисунок 16 - Койфлет (слева) первого порядка и его масштабирующая функция (справа)

Поскольку при обработке изображений бывает желательной

симметричность вейвлет-функций, был предложен класс вейвлетов с названием «симлеты», представитель которого был также исследован в настоящей работе.

Перспективным вейвлетом, который встречается в работах по интерпретации многозональных изображений, является вейвлет Шеннона-Котельникова, связанный с одноименной теоремой. Этот вейвлет, в некотором смысле, противоположен вейвлету Хаара. Масштабирующая функция Хаара представляет собой ступенчатую функцию, Фурье-образ $\hat{\varphi}(\omega)$ которой совпадает с $\sin(\omega/2)/(\omega/2)$ [68]. Если взять ступенчатую функцию в частотной области, то исходная масштабирующая функция примет вид:

$$\varphi(x) = \frac{\sin \pi x}{\pi x}, \quad (11)$$

что соответствует скейлинг-функции вейвлета Шеннона-Котельникова. Таким образом, вейвлет Хаара ограничен в пространственной области и представим ступенчатой функцией, в то время как вейвлет Шеннона-Котельникова ограничен в частотной области. В дискретном случае коэффициенты функции $\varphi(x)$ (11) выражаются по формуле [68]:

$$sh_n = \sqrt{2} \frac{1}{2\pi} \int_{-\pi/2}^{\pi/2} e^{i\omega n} d\omega = \begin{cases} \frac{1}{\sqrt{2}}, & n = 0, \\ (-1)^{\frac{n-1}{2}} \frac{\sqrt{2}}{\pi}, & n - \text{нечетное}, \\ 0, & \text{при других } n. \end{cases}$$

В данной работе использовался вейвлет с 7 коэффициентами: $-\frac{\sqrt{2}}{3\pi}, 0, \frac{\sqrt{2}}{\pi}, \frac{1}{\sqrt{2}}, \frac{\sqrt{2}}{\pi}, 0, -\frac{\sqrt{2}}{3\pi}$. Графики материнского вейвлета и масштабирующей функции представлены на рисунке 17.

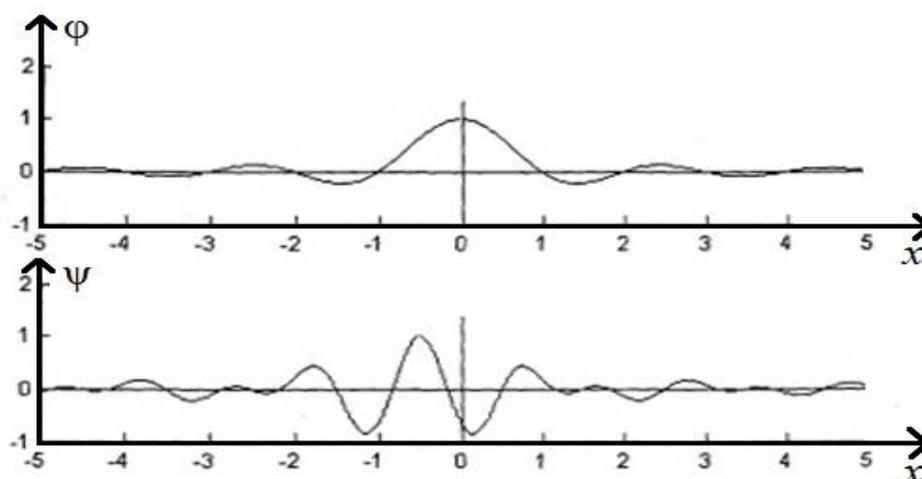


Рисунок 17 - Скейлинг-функция Шеннона-Котельникова (верхний график),
материнская вейвлет-функция Шеннона-Котельникова (нижний график)

Рассмотрим теорему Котельникова-Шеннона [68].

Предположим, что непрерывная интегрируемая с квадратом функция $f(t)$ на \mathbb{R} имеет преобразование Фурье $\hat{f}(\omega)$ с компактным носителем, лежащим на промежутке $[-\Omega; \Omega]$. Если шаг выборки Δt такой, что $\Delta t \leq \pi/\Omega$, то функция $f(t)$ может быть восстановлена единственным образом по выборочным данным $x_n = f(n\Delta t)$, $n \in \mathbb{Z}$ по формуле:

$$f(t) = \sum_{n \in \mathbb{Z}} f(n\Delta t) \frac{\sin\left(\frac{\pi}{\Delta t}t - \pi n\right)}{\frac{\pi}{\Delta t}t - \pi n}. \quad (12)$$

Теорема Котельникова-Шеннона утверждает, что если функция $f(t)$ обладает ограниченным по ширине Фурье-спектром, то она может быть полностью восстановлена по своим дискретным значениям по формуле (12).

Таким образом, использование функции $\text{sinc}(x) = \sin(x)/x$ в качестве скейлинг-функции позволяет получить семейство вейвлетов, которые должны предоставлять эффективный инструмент для описания сигналов с ограниченной шириной спектра.

Несмотря на большое количество существующих вейвлет-функций и исследований, посвященных их применению в различных областях, не существует чёткого руководства по выбору подходящей функции. Поэтому в настоящей работе выбраны вейвлет-функции, которые зарекомендовали себя в качестве эффективного инструмента обработки изображений в исследованиях других авторов.

2.3. Метод принятия обоснованного решения о классе распознаваемого объекта

Принятие решений в автоматизированных контролируемых методах классификации сводится к сравнению исследуемого образца с эталонными представителями классов объектов. Каждый объект, участвующий в процессе классификации (обучающие и тестовые образцы), представляется вектором признаков $\bar{y} = (y^1, y^2, \dots, y^n)$, где n – количество используемых признаков. В настоящей работе предлагается метод, относящийся к разделу алгоритмов, основанных на вычислении оценок. Рассмотрим общую концепцию работы таких алгоритмов.

Для алгоритмов, основанных на вычислении оценок, важным термином выступает понятие опорных множеств. Опорные множества представляют собой подмножества признаков, по которым происходит сравнение эталонов и объектов распознавания. Например, для алгоритма Кора [15] опорными множествами выступают тройки признаков, не совпадающих по разным классам, для тестовых алгоритмов [37] – тупиковые тесты.

Для опорного множества $\omega = \{y_1, y_2, \dots, y_k\}$ выбирается функция расстояния между объектами по ω и пороговое значение ε . Если объект распознавания \bar{x} сравнивается с объектом обучения \bar{x}_i по ω и

$$\rho(\omega\bar{x}, \omega\bar{x}_i) < \varepsilon,$$

где ρ – функция расстояния, то \bar{x} получает «голос» за тот класс, которому принадлежит \bar{x}_i . Решение принимается по большинству голосов для всех опорных множеств и объектов обучения.

Для улучшения качества распознавания могут быть использованы весовые коэффициенты для признаков и объектов обучения. В этом случае рассматривается многопараметрическая задача оптимизации.

Поскольку для описания многозональных изображений лесной растительности, необходимо использовать систему признаков, включающую в себя разнообразные, как спектральные так и структурные характеристики, то y_i могут быть, как непрерывными, так и дискретными. В настоящей работе применяется квантование значений признаков, что позволяет перевести все используемые признаки к одной области значений. Для этого на множестве обучающих векторов определяются минимальное и максимальное значения каждого признака и принимаются за левую и правую границы диапазона принимаемых значений:

$$d_p = \left[\min_{i=1,l} (y_i^p); \max_{i=1,l} (y_i^p) \right], p = \overline{1,n}.$$

где l - объем обучающей выборки. Полученные диапазоны d_p разбиваются на t равных сегментов. Количество сегментов t является параметром, задаваемым пользователем. Его выбор зависит от условий решаемой задачи: например, от количества исследуемых классов, используемой системы признаков и др. Но главным при определении количества сегментов являются показатели качества классификации, которые определяются в результате экспериментальных исследований предложенного метода.

В процессе квантования каждому объекту по i -му признаку ставится в соответствие набор $x^i = (x_1^i, x_2^i, \dots, x_t^i)$, в котором $x_j^i = 1$, если значение i -го признака попадает в сегмент j . При этом остальные компоненты этого набора приравниваются нулю. В случае, когда значение признака выходит за пределы

заданного диапазона d_p , единица присваивается либо x_{1^i} , либо x_{t^i} , в зависимости от того, за правую или левую границу вышло значение признака. Такой подход с квантованием значений признаков по сегментам приводит к дискретизации описания объектов распознавания. То есть, от непрерывных признаков y^i был осуществлен переход к бинарным векторам, которые представляют собой окончательные признаки, по которым будет происходить принятие решения. Описанная процедура позволяет перевести все признаки в один масштаб и формат, а также, как будет показано ниже, позволит провести теоретическую оценку достаточного объема контрольной выборки.

Таким образом, один объект обучения задается вектором:

$$\bar{x} = (x_1^1, x_2^1, \dots, x_t^1; x_1^2, x_2^2, \dots, x_t^2; \dots; x_1^n, x_2^n, \dots, x_t^n), \text{ где } \sum_{j=1}^t x_j^i = 1, i = \overline{1, n}. \quad (13)$$

В результате этапа обучения каждый класс распознавания C_k задается набором векторов соответствующих обучающих образцов. То есть, классу C_k соответствует объединение $\bigcup_{s=1}^{l_k} \bar{x}_s$, где l_k – количество объектов обучения, принадлежащих C_k .

Процедура классификации нового объекта распознавания \bar{x} , представленного в виде (13), сводится к сравнению \bar{x} с векторами \bar{x}_s обучающей выборки. При совпадении x^i с x_s^i ($\bar{x}_s \in C_k$) объект \bar{x} получает голос за класс C_k . Суммарное количество голосов по всем признакам определяет оценку принадлежности Φ_k объекта \bar{x} каждому классу C_k , $k = \overline{1, M}$. В результате объект относится к тому классу, для которого оценка Φ_k максимальна.

Свойства процедуры принятия решений позволяют отнести разработанный метод к семейству алгоритмов распознавания, основанных на вычислении оценок [18, 24]. При этом опорными множествами, по которым проводится сравнение объектов распознавания и обучения, выступают сегменты признаков.

Дискретный вид таблицы обучения позволяет получить оценки качества распознающего алгоритма в рамках теории минимизации эмпирического риска [14, 13]. Емкостью h семейства алгоритмов $F(\bar{x}, \alpha)$ (решающих правил), где α – индекс правила, называется максимальный объем выборки, которую можно разделить на два класса всеми возможными 2^h способами с помощью алгоритмов семейства $\{F(\bar{x}, \alpha)\}$. Если h конечна, то для правила $F(\bar{x}, \alpha)$, у которого эмпирический риск (частота ошибки) на случайной выборке объема L равен $\rho_3(\alpha)$, выполнено

$$P(|\rho(\alpha) - \rho_3(\alpha)| < \varepsilon) > 1 - \eta, \quad (14)$$

где $\rho(\alpha)$ – вероятность ошибки алгоритма $F(\bar{x}, \alpha)$, на всем пространстве объектов распознавания; $\varepsilon > 0$, $1 - \eta$ – заданная надежность. При этом объем выборки L и оценка точности ε связаны соотношением

$$L \sim \frac{h - \ln \eta}{\varepsilon}.$$

Если пространство объектов распознавания конечно, то оценка (14) остается справедливой для величины L , для которой

$$L \sim \frac{\ln N - \ln \eta}{\varepsilon},$$

где N – число различных, то есть, дающих разную классификацию, решающих правил семейства $\{F(\bar{x}, \alpha)\}$. Таким образом, в данном случае аналогом емкости выступает число $\ln N$.

Для предложенного описания векторов обучения число различных решающих правил не превосходит величины $t \cdot n \cdot l$. Следовательно, уклонение

вероятности ошибки от частоты ошибки оценивается величиной ε пропорциональной $\frac{nl \cdot \ln t}{L}$. Другими словами,

$$L \sim \frac{nl \cdot \ln t}{\varepsilon}.$$

Таким образом, объем контрольной выборки пропорционален размерности пространства признаков. Этот результат сравним с аналогичным результатом для распространенного семейства линейных решающих правил, для которого емкость h , а, следовательно, объем контрольной выборки L оценивается величиной $h=n+1$, где n – размерность пространства признаков [12].

Опишем предложенный метод классификации в алгоритмическом виде.

Обучение метода классификации:

1. Ввод данных.

Обучающие векторы признаков:

$$\begin{aligned} & \bar{x}_{11}, \bar{x}_{12}, \dots, \bar{x}_{1l_1}; \\ & \bar{x}_{21}, \bar{x}_{22}, \dots, \bar{x}_{2l_2}; \quad , \text{ где } \bar{x}_{ij} = (x_{ij}^1, x_{ij}^2, \dots, x_{ij}^n) \\ & \dots \\ & \bar{x}_{M1}, \bar{x}_{M2}, \dots, \bar{x}_{Ml_M} \end{aligned}$$

где M - количество классов; l_i - количество обучающих образцов i -го класса; n - количество признаков.

Количество сегментов: t .

2. Формирование диапазонов значений признаков.

$$d_1 = [a_1, b_1], \quad a_1 := \min_{i,j} x_{ij}^1, \quad b_1 := \max_{i,j} x_{ij}^1$$

...

$$d_n = [a_n, b_n], \quad a_n := \min_{i,j} x_{ij}^n, \quad b_n := \max_{i,j} x_{ij}^n.$$

3. Сегментирование диапазонов значений признаков.

$$d_1 = [d_{10}, d_{12}, \dots, d_{1t}], \quad d_{10} := a_1, d_{12} := a_1 + h_1, \dots, d_{1t} = b_1, \quad h_1 = \frac{b_1 - a_1}{t};$$

...

$$d_n = [d_{n1}, d_{n2}, \dots, d_{nt}], \quad d_{n0} := a_n, d_{n2} := a_n + h_n, \dots, d_{nt} = b_n; \quad h_n = \frac{b_n - a_n}{t}.$$

4. Построение вспомогательных бинарных массивов распределения значений признаков по сегментам U^i ($i = \overline{1, n}$) размером $M \times t$.

Для $i = \overline{1, n}$:

Для $j = \overline{1, M}$:

$$U_{js}^i = \begin{cases} 1, & \text{если значение хотя бы одного образца } j\text{-го класса попадает в сегмент } s \\ 0, & \text{иначе} \end{cases}$$

5. Построение массивов достоверностей μ^i ($i = \overline{1, n}$) размером $M \times t$.

Для $i = \overline{1, n}$:

$$\mu_{js}^i = \frac{\frac{m_{js}^i}{l_j}}{\sum_{j=1}^M \frac{m_{js}^i}{l_j}}, \quad j = \overline{1, M}; s = \overline{1, t},$$

где l_j – количество обучающих образцов j -го класса, m_{js}^i – количество образцов j -го класса, значения которых по признаку i попало в сегмент s с номером s .

На этапе обучения на вход подаются фрагменты изображений, представляющие собой эталоны (принадлежность которых к классам известна), в виде векторов вейвлет-признаков. Выполняются следующие действия: на основании полученных эталонных значений признаков формируются диапазоны принимаемых значений; полученные диапазоны разбиваются на равные по размерам сегменты; для каждого i -го признака строится вспомогательный массив U^i и массив достоверности μ^i [12].

Массивы U^i характеризуют распределение значений признаков разных классов по сегментам. Эти бинарные массивы и представляют собой окончательное описание, по которому будет происходить принятие решения.

Элементы массива достоверности μ_{js} характеризуют вероятность того, что образец принадлежит классу с номером j , при условии попадания значения рассматриваемого признака в сегмент с номером s .

Таким образом, результатом обучения классификатора являются массивы U^i ($i = \overline{1, n}$), описывающие распределение значений признаков по сегментам, а также массивы достоверностей.

Этап принятия решения:

1. Ввод данных.

Вектор признаков тестового образца:

$$\bar{y} = (y_1, y_2, \dots, y_n).$$

2. Формирование бинарных векторов распределения значений признаков по сегментам.

$$\bar{v} = (v_{ij})_{\substack{i=\overline{1, n} \\ j=\overline{1, t}}} := (0, 0, \dots, 0).$$

Для $i = \overline{1, n}$:

если $y_i \in [d_{ij}, d_{i, j+1}]$ ($j = \overline{0, t-1}$), то $v_{ij} := 1$.

3. Расчёт оценок принадлежности тестового образца к исследуемым классам объектов.

Для $j = \overline{1, M}$:

$$\Phi_j = \sum_{i=1}^n \sum_{s=1}^t v_{is} \cdot \mu_{js}^i$$

4. Принятие решения о принадлежности тестового образца к классу объектов.

Образец относится к классу с номером p , где $\Phi_p = \max_{j=1, M} \Phi_j$.

При принятии решения исследуемый образец, для которого необходимо определить класс объекта, подается на вход алгоритма в виде вектора вейвлет-признаков. Дальнейшие действия можно описать следующими этапами: для каждого признака определяется номер соответствующего сегмента, в результате

чего тестируемый образец описывается бинарным вектором, состоящим из n наборов сегментов признаков, где единицами обозначаются сегменты, в которые попадают значения признаков исследуемого образца; вычисляются оценки принадлежности классам; исследуемый образец относится к тому классу, для которого значение оценки принадлежности максимально.

Таким образом, можно говорить о том, что представленный алгоритм классификации многозональных изображений относится к семейству алгоритмов распознавания, основанных на вычислении оценок. При этом особенностями алгоритма является квантование значений признаков, использование сегментов признаков в качестве опорных множеств.

Отметим возможность применения весовых коэффициентов признаков. Для того чтобы в рассматриваемом семействе решающих правил с большей вероятностью существовал алгоритм, дающий малую частоту ошибок на контрольной выборке, целесообразно расширить семейство за счет введения весовых коэффициентов признаков. В настоящем методе в этом качестве предлагается использовать показатель значимости. Принимая некоторое пороговое значение N этого показателя и, таким образом, включая в процесс классификации только те признаки, значимость которых превышает N , рассматриваемый алгоритм позволит уменьшить вероятность ошибки распознавания.

2.4. Алгоритмические и методические основы выбора информативных признаков

Для достижения разностороннего и максимально полного описания исследуемых объектов система признаков должна быть представительной. При этом количество признаков в системе становится чрезмерно большим. Например, если использовать только спектральные признаки (значения пикселей) гиперзонального снимка, то размерность системы признаков может превышать 200. Комбинированная система признаков, которая, как было показано в п. 2.1,

необходима для решения поставленной задачи, может превосходить этот показатель в несколько раз. Большая размерность системы признаков, как правило, оказывает отрицательное влияние на результаты классификации. Это происходит, потому что при большом количестве признаков негативные воздействия каждого из них складываются и не выполняется гипотеза компактности [4]. Таким образом, перед этапом принятия решения необходимо проводить отбор наиболее информативных характеристик из общего объема сформированной системы.

Наиболее известным методом уменьшения признакового пространства является метод главных компонент [131]. Суть метода главных компонент (Principal Component Analysis (PCA)) состоит в следующем. Набор эталонов представляется матрицей X размером $n \times m$, где n – количество эталонов, m – количество признаков, которыми они описываются. Используются новые формальные переменные s_a ($a=1, \dots, A$), которые являются линейными комбинациями исходных переменных x_i ($i=1, \dots, m$), то есть, определяются формулами типа:

$$s_a = p_{a1}x_1 + \dots + p_{am}x_m.$$

С помощью новых переменных матрица X представляется произведением двух других матриц S и P . То есть,

$$X = SP^t + E = \sum_{a=1}^A s_a p_a^t + E,$$

где S ($n \times A$) называют матрицей счётов, P ($A \times m$) матрицей нагрузок, E – матрицей остатков ($n \times m$). В результате получаем, что вместо переменных x_i исходная матрица X представима переменными t_a , которые и называют главными компонентами. Число A заведомо меньше числа m , что и обеспечивает уменьшение размерности признакового пространства. При этом главные

компоненты обеспечивают учёт всех переменных и представляют наиболее информативную часть исходного набора данных.

Таким образом, метод главных компонент способен уменьшать признаковое пространство, сохраняя при этом максимум информации. Однако, этот метод подразумевает под наиболее существенными признаками те характеристики, которые имеют максимальный разброс значений. Для задач распознавания объектов гораздо более существенно чтобы, признаки обладали разделяющей способностью, то есть значения признаков для разных классов должны находиться в разных зонах всего диапазона их значений. Поэтому для решения поставленной задачи метод главных компонент не представляется эффективным инструментом отбора признаков.

В настоящей работе для отбора признаков используется формула (15), представленная в работе [12] и предназначенная для классификации объектов в базах данных.

$$F = 1 - \left(\frac{\sum_{i=1}^M \sum_{j=1}^t \left(u_{ij} \cdot \sum_{k=1, k \neq j}^M u_{kj} \right)}{\sum_{j=1}^t u_{ij}} \right) / (M \cdot (M - 1)), \quad (15)$$

где M – количество классов, t – количество сегментов, на которое разбиты диапазоны значений признаков. Показатель значимости признаков (15) является характеристикой, которая оценивает то, насколько хорошо признак разделяет классы. Эта характеристика может принимать значения от 0 до 1, где 0 означает, что признак не обладает разделяющей способностью, а 1 – признак обладает максимальной разделяющей способностью с точки зрения предложенной оценки значимости. Показатель значимости равный единице означает, что значения рассматриваемого признака для разных классов попадают в разные сегменты.

Допустим, исследуется 3 класса объектов, а разбиение проводилось на 6 сегментов, и для некоторого признака был получен следующий массив u :

$$u = \begin{pmatrix} 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{pmatrix}. \quad (16)$$

То есть, значения рассматриваемого признака эталонов класса 1 попадают в сегменты 1,2, эталоны класса 2 – в сегменты 3,4, а эталоны класса 3 – в сегменты 5,6. Рассчитаем показатель значимости:

$$F = 1 - \left(\frac{1 \cdot 0 + 1 \cdot 0 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1}{2} + \frac{0 \cdot 1 + 0 \cdot 1 + 1 \cdot 0 + 1 \cdot 0 + 0 \cdot 1 + 0 \cdot 1}{2} + \frac{0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 0 \cdot 1 + 1 \cdot 0 + 1 \cdot 0}{2} \right) / (2 \cdot 3) = 1 - \frac{0}{6} = 1$$

Таким образом, признак, представимый для рассматриваемого набора классов массивом u (16), обладает максимальной значимостью.

Рассмотрим противоположный случай, когда значения признака по всем классам максимально разбросаны. Тогда массив u примет вид:

$$u = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \end{pmatrix}.$$

Рассчитаем показатель значимости:

$$F = 1 - \left(\frac{1 \cdot 2 + 1 \cdot 2}{2} + \frac{1 \cdot 2 + 1 \cdot 2}{2} + \frac{1 \cdot 2 + 1 \cdot 2}{2} \right) / (2 \cdot 3) = 1 - \frac{6}{6} = 0.$$

Получаем, что значимость такого признака минимальна. Таким образом, описанный показатель значимости признаков позволяет оценивать разделимость классов по каждой характеристике в выбранной системе признаков. Важным параметром является количество сегментов разбиения диапазонов значений.

Описанный показатель F может быть использован не только для предварительного отбора наиболее информативных признаков, но и в качестве весового коэффициента при подсчёте голосов за классы. Тогда в представленном в п.2.2 алгоритме на 4 шаге этапа обучения для каждого признака необходимо рассчитать определенный формулой (15) показатель значимости, а при принятии решения для расчета оценки принадлежности объекта классу использовать формулу: $\Phi_i = \sum_{j=1}^n \sum_{s=1}^t F_j \cdot \mu_{js}^i$. При вычислении оценок Φ_i наиболее значимые признаки будут больше влиять на результат, чем признаки, которые обладают меньшей разделяющей способностью.

Весь предложенный метод классификации, включающий в себя этапы обучения и принятия решения, а также использование коэффициентов значимости для уменьшения признакового пространства, можно представить в виде блок-схемы на рисунке 18.

2.5. Выводы по Главе 2

1. Проведен системный анализ задачи интерпретации космических снимков площадных объектов местности, в результате которого изучены факторы, влияющие на формирование и интерпретацию изображений, выявлен класс трудноразличимых объектов на снимке, требующий разработки нового более эффективного метода интерпретации.

2. Предложена дешифровочная система признаков, основанная на вейвлет-преобразовании, которое для изображения осуществляется с помощью быстрого алгоритма двумерного ДВП Малла. В качестве вейвлет-функций используются: вейвлеты Хаара, Добеши, Шеннона-Котельникова, симлет и койфлет.

3. Разработан метод классификации, основанный на вычислении оценок, где опорными множествами выступают сегменты диапазонов значений признаков. Произведена теоретическая оценка необходимого объема контрольной выборки для предложенного метода классификации.

4. Предложено использование функции значимости для отбора наиболее информативных признаков, с целью повышения точности классификации и уменьшения признакового пространства.

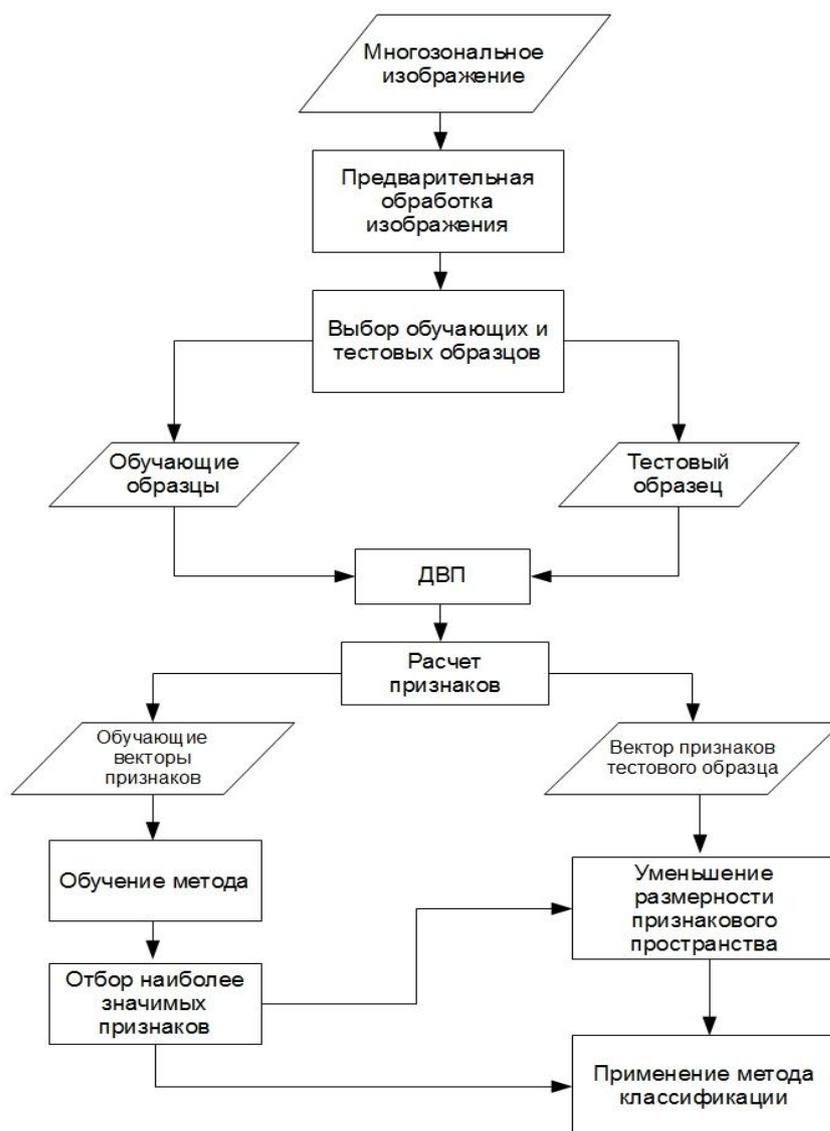


Рисунок 18 - Блок-схема предложенного метода интерпретации космических снимков, включающего в себя метод классификации, основанный на вычислении оценок

Глава 3. Система признаков мультиспектральных данных для их интерпретации

3.1. Базовая система признаков

Объекты лесной растительности на снимках высокого разрешения являются трудноразличимыми. Поэтому для их распознавания с высокой точностью необходимо использовать систему признаков, включающую в себя разносторонние характеристики спектральных и структурных свойств изображений объектов. В этом смысле, перспективным способом (как показано в п.1.5.) является использование вейвлет-преобразования изображения. Вейвлет-преобразование представляет собой разложение исходного сигнала по базису вейвлет-функций, которые являются «функциями типа маленькой волны, которые порождают базисы гильбертова пространства, удобные для обработки сигналов» [68]. Главное преимущество вейвлет-преобразования состоит в том, что оно описывает исходный сигнал сразу в двух областях – пространственной и частотной. А использование вейвлет-преобразования в разных спектральных каналах изображения позволяет описать спектральные свойства. В настоящей работе применяется двумерное дискретное вейвлет-преобразование (ДВП), выполняемое с помощью алгоритма быстрого вейвлет-преобразования Малла, в результате которого создается несколько изображений ДВП, характеризующих аппроксимацию, горизонтальные, вертикальные и диагональные детали исходного изображения.

Базовая система признаков, исследуемая в настоящей работе, состоит из средних значений и стандартных отклонений, рассчитанных по изображениям ДВП. Для исследования эффективности этой системы признаков было выполнено экспериментальное исследование на снимке спутника QuickBird, пространственное разрешение которого 2.44 м. Для формирования системы признаков использовалось вейвлет-преобразование Хаара первого уровня. Поскольку снимок QuickBird имеет 4 спектральных канала, а один уровень ДВП

порождает 4 изображения ДВП, по каждому из которых рассчитываются 2 показателя, то общее количество признаков составило 32.

В качестве классификатора был применен метод минимального расстояния Евклида. Было рассмотрено 4 класса объектов: хвойные леса, лиственные леса, вырубки с порослью, леса с остатками снега. В результате тестирования на 10 эталонных образцах каждого класса получили безошибочный результат, т.е. процент успешной классификации (или общая точность) составил 100 %. Поскольку рассматриваемые объекты представляют собой растительность, то можно было бы ожидать, что использование вегетационных индексов также может успешно справиться с задачей классификации. Однако, используя в качестве признака индекс NDVI, процент успешной классификации для отдельных классов изменяется от 70 % до 100 %. Таким образом, характеристики, вычисленные на основе вейвлет-преобразования, способны с высокой точностью классифицировать трудноразличимые (по Живичину) объекты (см. п.1.1).

При исследовании группы признаков, построенной на основе изображений ДВП, полученных в результате нескольких уровней преобразования, рассматривались такие параметры как количество уровней ДВП и используемая вейвлет-функция. Сравнение признаков при разных наборах параметров происходило на основании результатов классификации, а именно, с помощью показателя общей точности и коэффициента каппа [95].

Поскольку изображения лесной растительности на снимке, как правило, обладают текстурой, то для предварительного исследования системы признаков было выбрано 5 изображений из альбома текстур Бродаца, которые представлены на рисунке 19. Необходимо отметить, что изображения текстур из альбома Бродаца являются общепринятым источником тестирования алгоритмов и программ распознавания изображений [93]. Это удобная модель для исследования свойств предложенного метода. Выбранные изображения обладают близкими значениями среднего тона и стандартного отклонения (таблица 3).

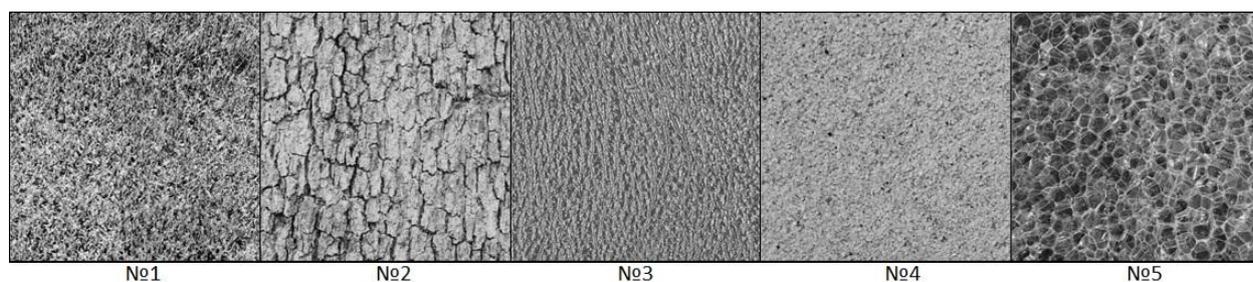


Рисунок 19 - Изображения из альбома текстур Бродаца

Таблица 3 - Характеристики изображений текстур из альбома Бродаца

Номер изображения	Средний тон	Размер деталей, %	Наличие анизотропии	Стандартное отклонение
1	128.67	0.05	-	52.95
2	148.51	0.61	+	46.99
3	128.86	0.72	+	39.17
4	155.70	0.04	-	28.45
5	111.38	0.49	+	39.33

В графе «Размер деталей» в таблице 3 представлена величина, характеризующая процентное соотношение среднего размера детали к размеру изображения. Данные, представленные в таблице, позволяют говорить о том, что выбранные образцы мало отличаются по их значениям среднего тона и стандартного отклонения (что характерно для многозональных изображений лесов); у трех из пяти образцов наблюдается анизотропия (что характерно для вырубок и посадок лесных культур); значительные размеры деталей образцов №2, 3 и 5 соответствуют таким объектам как городские постройки, средние и мелкие размеры деталей образцов №1 и 4 соответствуют таким объектам как леса. Таким образом, образцы, представленные на рисунке 16, могут служить моделями реальных изображений площадных объектов местности, полученных с помощью методов дистанционного зондирования.

Каждое из изображений на рисунке 16 в ходе исследования рассматривалось в качестве одного класса распознавания. Таким образом, были проведены эксперименты по распознаванию 5 классов объектов, где для обучения

и тестирования использовалось по 5 непересекающихся образцов каждого класса размерами 64×64 пикселя. В качестве метода классификации использовался метод минимального расстояния, где в качестве меры расстояния выступали: прямоугольная мера (17), расстояние Евклида (18) и угловая мера (19).

$$L_1 = |\mu_a - \mu| = \sum_{k=1}^N |m_{ak} - m_k|, \quad (17)$$

$$L_2 = |\mu_a - \mu| = \sqrt{\sum_{k=1}^N (m_{ak} - m_k)^2}, \quad (18)$$

$$L_3 = |\mu_a - \mu| = \arccos\left(\frac{\mu_a^T \mu}{\|\mu_a\| \|\mu\|}\right), \quad (19)$$

где μ_a – вектор признаков класса a , μ – вектор признаков тестового образца, N – количество признаков. Полученные результаты классификации сведены в табл. 4.

Таблица 4 - Общие точности результатов классификации текстур из альбома Бродаца с использованием базовой системы признаков

Вейвлет-функция	Прямоугольное расстояние (L_1)	Евклидово расстояние (L_2)	Угловое расстояние (L_3)
Хаара	96 %	96 %	76 %
Добеши (D-4)	96 %	96 %	72 %
Симлет	96 %	96 %	72 %
Койфлет	96 %	96 %	72 %
Шеннона-Котельникова	96 %	96 %	84 %

Таким образом, система признаков, построенная на основе одноуровневого вейвлет-преобразования, и включающая в себя средние значения и стандартные отклонения изображений ДВП, способна эффективно распознавать текстурные изображения. Отметим, что использование углового расстояния приводит к общей точности, которая ниже 80 % (за исключением использования вейвлета Шеннона-Котельникова).

Для оценки эффективности применения ДВП более высоких уровней, было проведено сравнение результатов классификации, полученных при распознавании тех же 5 текстур Бродаца, с использованием систем признаков, построенных на одном, двух, трех и четырех уровнях вейвлет-преобразования Хаара (выбор функции Хаара обусловлен его простотой, что ускоряет процесс вычислений). Полученные результаты сведены в таблицу 5 и представлены графически на рисунке 20.

Таблица 5 - Результаты (общая точность) классификации текстур из альбома Бродаца с помощью базовой системы признаков, построенной на разном количестве уровней ДВП

	1 уровень ДВП	2 уровень ДВП	3 уровень ДВП	4 уровень ДВП
L_1	96 %	96 %	96 %	92%
L_2	96 %	96 %	88 %	84 %
L_3	76 %	84 %	80 %	68 %

Полученные результаты позволяют говорить о том, что высокие уровни ДВП не всегда обеспечивают рост показателей точности классификации. Поэтому целесообразно исследовать систему признаков, которая будет строиться на основе лишь 1 уровня ДВП, дополненную другими структурными признаками.

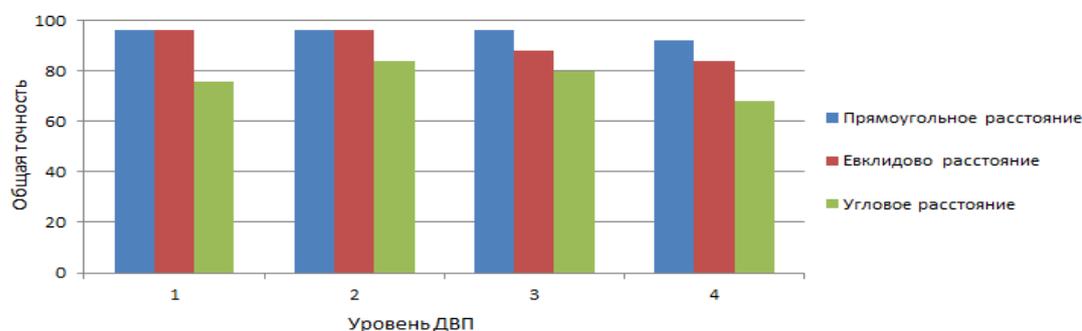


Рисунок 20 - Результаты классификации, приведенные в таблице 5.

Подводя итог экспериментов на модельных изображениях текстур из альбома Бродаца, можно заключить, что предложенные признаки позволяют с высокой точностью распознавать текстурные изображения, характеристики которых представлены в таблице 3. Кроме того, установлено, что увеличение уровня ДВП при вычислении признаков не гарантирует увеличения точности классификации.

Более глубокое исследование системы признаков производилось на мультиспектральных данных снимка RapidEye. Было рассмотрено 6 классов объектов лесной растительности. При этом методом классификации выступал предложенный метод, основанный на вычислении оценок. Прежде всего, исследовалась зависимость результатов классификации от материнской вейвлет-функции при фиксации одного уровня преобразования и 6 сегментов разбиения диапазонов значений признаков. Для рассмотрения было выбрано 5 вейвлет-функций: Хаара, Добеши, койфлет, симлет и вейвлет Шеннона-Котельникова. Выбор именно таких функций был основан на работах других исследователей [100, 93, 134]. Полученные результаты представлены в виде общей точности и коэффициента каппа в таблице 6.

Таблица 6 - Результаты классификации с использованием разных вейвлет-функций при формировании системы признаков

Вейвлет-функция	Общая точность	Коэффициент каппа
Хаара	90%	0.87
Добеши	87%	0.85
Койфлет	84%	0.81
Симлет	93%	0.91
Шеннона-Котельникова	93%	0.91

Полученные результаты позволили сделать вывод о том, что в рамках нашей задачи классификации объектов лесной растительности, наиболее подходящими вейвлет-функциями выступают вейвлеты Хаара, Шеннона-

Котельникова и симлет. Дальнейшие исследования выполнялись с использованием именно этих трех функций.

В таблице 7 представлены результаты, полученные при классификации тех же шести классов объектов на снимке RapidEye с использованием признаков, построенных на разных уровнях ДВП и с разными вейвлет-функциями.

Таблица 7 - Результаты классификации с использованием признаков, построенных на разных уровнях ДВП и с использованием разных вейвлет-функций

	1 уровень ДВП		2 уровень ДВП		3 уровень ДВП	
	ОГ	К	ОГ	К	ОГ	К
Хаара	90%	0.87	90%	0.87	90%	0.88
Симлет	93%	0.91	89%	0.86	92%	0.90
Шеннона-Котельникова	93%	0.91	89%	0.86	90%	0.87

Эти же результаты представлены графически на рисунке 21, где на горизонтальной оси цифрами 1,2,3 отмечены уровни ДВП, а на вертикальной оси – коэффициенты каппа. По графику можно говорить о том, что вейвлет Хаара показывает наиболее низкие результаты классификации на всех трёх уровнях ДВП. А вейвлет Шеннона-Котельникова и симлет достигают наибольшего значения точности классификации на первом уровне ДВП.

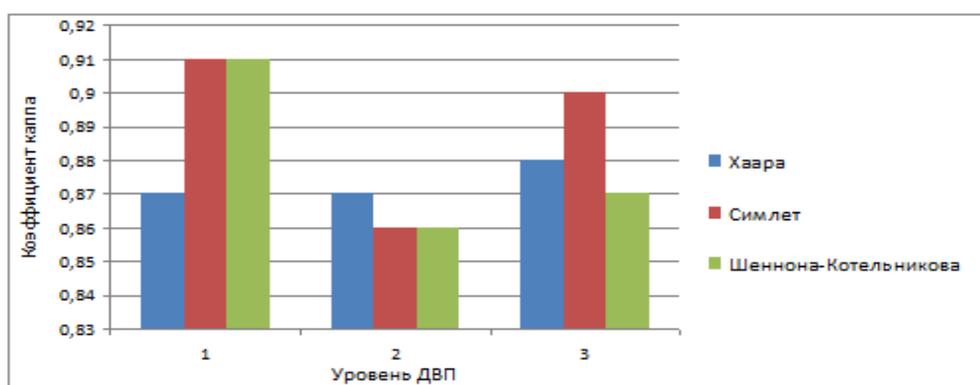


Рисунок 21 - Результаты классификации, представленные в таблице 7

Таким образом, наиболее эффективными признаками при рассмотрении объектов лесной растительности выступают вейвлет-признаки, рассчитанные на одном уровне ДВП с помощью функции Шеннона-Котельникова и симлета. Однако если рассмотреть максимальное количество признаков, то есть, случай с трехуровневым преобразованием, и проанализировать функции значимости (таблица 8), то можно заметить, что в число наиболее информативных войдёт несколько признаков, сформированных по результатам 2 и 3 уровня вейвлет-преобразования. Следовательно, признаки, рассчитанные на каждом новом уровне, могут обладать полезной информативностью в рамках решения поставленной задачи. С другой стороны, существуют признаки, рассчитанные на высоких уровнях ДВП (на 2-м уровне и выше), которые обладают низкой информативностью. Поэтому, перед процедурой классификации стоит установить порог на функцию значимости признаков, что позволит уменьшить признаковое пространство и рассматривать только те характеристики, которые эффективны в рамках исследуемой проблемы.

Таблица 8 - Значимость признаков, построенных на основе трехуровневого вейвлет-преобразования Шеннона-Котельникова

Значимость	Признак
0.836	Стандартное отклонение изображения аппроксимации. 1 уровень. 2 канал
0.830	Среднее значение изображения аппроксимации. 2 уровень. 5 канал
0.814	Среднее значение изображения вертикальных деталей. 1 уровень. 5 канал
0.808	Среднее значение изображения горизонтальных деталей. 1 уровень. 5 канал
0.803	Среднее значение изображения вертикальных деталей. 1 уровень. 4 канал
0.803	Среднее значение изображения диагональных деталей. 1 уровень. 5 канал
0.800	Среднее значение изображения аппроксимации. 1 уровень. 5 канал
0.800	Среднее значение изображения аппроксимации. 3 уровень. 5 канал
0.797	Среднее значение изображения горизонтальных деталей. 2 уровень. 5 канал
0.794	Среднее значение изображения аппроксимации. 1 уровень. 4 канал
0.794	Среднее значение изображения аппроксимации. 2 уровень. 4 канал

Продолжение таблицы 8

Значимость	Признак
0.794	Среднее значение изображения горизонтальных деталей. 2 уровень. 4 канал
0.794	Среднее значение изображения аппроксимации. 3 уровень. 4 канал
0.778	Стандартное отклонение изображения вертикальных деталей. 1 уровень. 5
0.775	Среднее значение изображения вертикальных деталей. 3 уровень. 4 канал
0.772	Среднее значение изображения диагональных деталей. 1 уровень 4 канал
0.767	Стандартное отклонение изображения аппроксимации. 1 уровень. 4 канал
0.763	Среднее значение изображения горизонтальных деталей. 3 уровень. 5 канал
0.761	Среднее значение изображения вертикальных деталей. 3 уровень. 5 канал

Дальнейшее исследование зависимости результатов классификации от используемой системы признаков рассматривается в Главе 4.

3.2. Базовая система признаков, дополненная характеристиками бинарного представления изображений ДВП

В настоящем разделе решается задача построения эффективного описания на основе изображений первого уровня ДВП. В этом случае для каждого канала многозонального изображения имеется 4 изображения ДВП, для каждого из которых система признаков включает характеристики, которые условно можно разбить на три группы.

Первая группа характеристик включает в себя средние значения (1) и стандартные отклонения (2) по матрицам всех изображений ДВП, то есть, ранее рассмотренные признаки, показавшие свою эффективность. Поскольку на 1 уровне преобразования имеем 4 изображения ДВП, то для одного канала изображения получится восемь признаков.

Во вторую группу входят признаки, характеризующие особенности бинарных массивов с заданными порогами (см. п.2.2.):

- количество пикселей, превышающих среднее значение;

- количество пикселей, превышающих 0.75 от среднего значения;
- количество пикселей, превышающих 1.25 от среднего значения;
- количество пикселей меньше 0;
- количество пикселей меньше 0.25 от среднего значения.

Таким образом, во второй группе 5 признаков, рассчитываемых для каждого изображения ДВП. Тогда при формировании системы признаков на основе одного уровня ДВП получим 20 признаков для 1 канала многозонального изображения.

К третьей группе признаков относятся характеристики пиков на уровне среднего значения по матрицам изображений ДВП. При этом пиком мы называем сплошной участок пикселей, которые превышают заданный уровень (в данном случае, это уровень среднего значения). Пики, площадь которых не превышала 3 пикселя, выбрасывались из рассмотрения. В систему признаков входят следующие характеристики:

- количество пиков;
- средняя площадь пиков;
- площадь максимального пика.

В третьей группе 3 признака, рассчитываемых для каждого из 4 изображений ДВП первого уровня. Таким образом, для одного канала изображения размерность признакового пространства составляет 40.

Эффективность предложенной системы признаков была первоначально исследована на модельных изображениях текстур из альбома Бродаца (рис.16). Методом принятия решения выступал предложенный нами метод, основанный на принципе голосования признаков, где параметр "количество сегментов" принимался равным 6, при формировании признаков использовался вейвлет Хаара. Тестирование проводилось для 5 образцов каждого класса, общая точность составила 96 %. Для анализа информативности используемых признаков были рассмотрены величины показателя значимости используемых 40 признаков. Признаки и показатели их значимости приведены в таблице 9.

Таблица 9 - Признаки при распознавании текстур из альбома Бродаца, показатели значимости которых превышают 0.5

Признак	Значимость
Изображение вертикальных деталей, стандартное отклонение	0.82
Изображение аппроксимации, стандартное отклонение	0.78
Изображение аппроксимации, среднее значение	0.71
Изображение аппроксимации. Количество пикселей, превышающих 1.75 от среднего	0.71
Изображение аппроксимации. Количество пикселей, превышающих 0.75 от среднего	0.68
Изображение аппроксимации. Количество пикселей, превышающих среднее значение	0.66
Изображение горизонтальных деталей. Стандартное отклонение.	0.60
Изображение аппроксимации. Максимальная площадь пиков.	0.60
Изображение вертикальных деталей. Количество пикселей, превышающих 1.75 от среднего значения.	0.56
Изображение горизонтальных деталей. Количество пикселей, превышающих 0.75 от среднего значения.	0.54
Изображение горизонтальных деталей. Количество пикселей меньше 0,25 от среднего значения.	0.54
Изображение горизонтальных деталей. Количество пикселей, превышающих среднее значение	0.53
Изображение горизонтальных деталей. Количество пикселей, превышающих 1.75 от среднего значения	0.50

Анализ таблицы показывает, что в число наиболее информативных признаков входят представители всех трех условных групп, введенных ранее.

Работа предложенной системы признаков была апробирована при распознавании 6 классов объектов лесной растительности на снимке съемочной системы RapidEye. На основе предыдущих исследований были отобраны вейвлеты Хаара, Шеннона-Котельникова и симлет. Результаты, полученные с использованием перечисленных функций для формирования системы признаков №2, приведены в таблице 10. Поскольку используемый снимок обладает 5

спектральными каналами и для одного канала определено 40 признаков, то общее количество признаков составило 200. При работе с таким большим признаковым пространством необходимо провести отбор наиболее значимых для процесса классификации признаков. Для этой цели в главе 2 была введена функция значимости F (2). При проведении классификации для признаков был установлен порог h функции значимости F , который в разных экспериментах принимался равным 0, 0.4, 0.5, 0.6, 0.7. В таблице 10 буквой N обозначено количество признаков, участвующих в классификации.

Таблица 10 - Результаты классификации с использованием дополненной системы признаков

Вейвлет-функция	h=0	h=0.4		h=0.5		h=0.6		h=0.7	
	ОТ, %	ОТ, %	N						
Хаара	80.8	88.3	46	90.4	23	90.4	15	89.4	10
Шеннона-Котельникова	95.7	96.8	48	94.7	27	94.7	19	92.5	15
Симлет	77.7	89.4	54	93.6	21	94.7	14	88.3	11

В первой колонке представлены результаты, полученные при использовании всех 200 признаков. Результаты для разных вейвлет-функций таковы. Наилучший результат получен для вейвлета Шеннона-Котельникова. Для Хаара и симлета наилучшие результаты получены при использовании признаков, значимости которых превышают 0.6. Для Хаара результат в области 90 %, для симлета – 94-95 %. При этом количество признаков уменьшено с 190 до 15 и 14 соответственно. Для вейвлета Шеннона-Котельникова был получен ещё более высокий результат (97 %). Он был получен при использовании признаков, значимость которых превышает 0.4. Количество таких признаков равно 48. При этом стоит отметить, что в число этих признаков вошли представители всех трех групп признаков рассмотренной системы.

Сравним результаты систем признаков, рассмотренных в предыдущем и настоящем параграфах. В таблице 11 сведены результаты, полученные при исследовании классов растительности на снимке RapidEye. В первой колонке представлена общая точность при использовании системы признаков, построенной на основе анализа бинарных массивов. Во второй колонке представлены результаты, полученные с применением системы признаков, состоящей только из средних значений и стандартных отклонений изображений ДВП первого уровня, а в третьем столбце – те же признаки, рассчитанные для изображений ДВП трёх уровней.

Таблица 11 - Сравнительная таблица для двух предложенных систем признаков

	Дополненная система признаков	Базовая система признаков; 1 уровень ДВП	Базовая система признаков; 3 уровня ДВП
Хаара	90 %	90 %	92 %
Симлет	95 %	93 %	93 %
Шеннона-Котельникова	97 %	93 %	98 %

Анализ представленных в таблице результатов позволяет говорить о том, что целесообразно использовать систему признаков, строящуюся на основе бинарных представлений изображений ДВП первого уровня, после чего проводить отбор наиболее значимых признаков, уменьшая тем самым используемое признаковое пространство.

3.3. Исследование эффективности и устойчивости признаков

Поскольку на реальном космическом снимке объекты, представляющие один и тот же класс, могут располагаться со смещениями и поворотами относительно фрагментов, использованных для обучения, то необходимо

выяснить, являются ли предложенные в этой работе признаки инвариантными относительно операций поворота и сдвига.

Для анализа инвариантности были использованы изображения из альбома текстур Бродаца, это классы №1, 3 и 4, представленные на рисунке 22, а также фрагменты снимка Quickbird (2.4 м), представляющие классы №2 и 5 для анализа инвариантности признаков.

Изображения, использованные для экспериментов по устойчивости к сдвигам и поворотам, могут быть описаны следующим образом.

Класс 1. Изображение из альбома текстур Бродаца. Изображение характеризуется совокупностью мелких деталей со средней контрастностью. Выраженная анизотропия отсутствует.

Класс 2. Изображение со снимка съемочной системы QuickBird. Отображаемые объекты представляют городскую застройку. Изображение характеризуется совокупностью мелких деталей с наличием протяженных линейных объектов. Контрастность деталей высокая. Глобальная анизотропия отсутствует.

Класс 3. Изображение из альбома текстур Бродаца. Изображение характеризуется совокупностью мелких деталей со средней контрастностью. Имеет место выраженная анизотропия изображения.

Класс 4. Изображение из альбома текстур Бродаца. Изображение характеризуется совокупностью мелких деталей с пониженной контрастностью. Выраженная анизотропия отсутствует.

Класс 5. Изображение со снимка съемочной системы QuickBird. На фрагменте представлен лиственный лесной массив с остатками снега (время съемки: апрель). Изображение характеризуется совокупностью мелких контрастных деталей. Анизотропия изображения отсутствует.

На представленных на рисунке 22 фрагментах было взято по 10 тестовых образцов каждого класса размерами 64×64 пикселей.

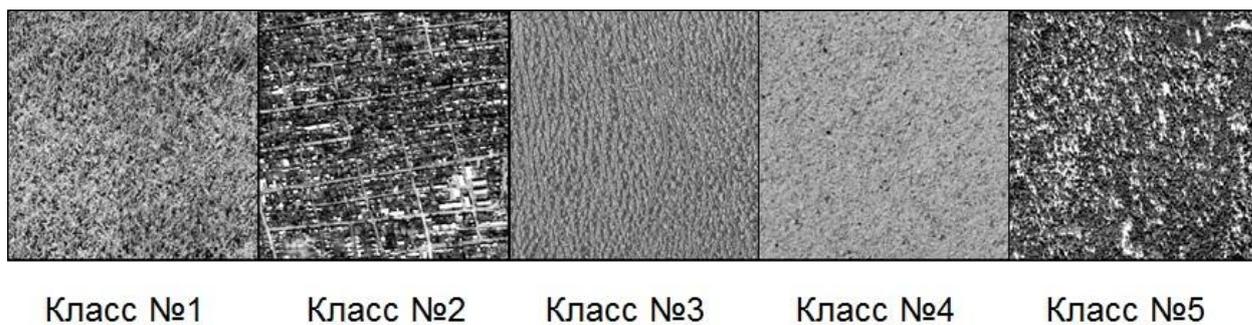


Рисунок 22 - Текстурные классы объектов для анализа устойчивости признаков при операциях сдвигов и поворотов

Для оценки влияния сдвигов и поворотов на исследуемые признаки и весь метод классификации в целом используется показатель общей точности (ОТ) классификации, а также модуль средних отклонений по j -му признаку, вычисляемый по формуле:

$$M_j = \frac{1}{N} \cdot \sum_{i=1}^N \frac{|x_i - \tilde{x}_i|}{|x_i|} \cdot 100\% , \quad (20)$$

где x_i – значение признака i -го образца; \tilde{x}_i – значение признака того же i -го образца, к которому было применено преобразование (операция сдвига или поворота); N – количество исследуемых образцов. То есть, показатель (20) представляет собой среднее значение отношений модуля разности признака j до преобразования и после преобразования к модулю исходного значения признака j по всем тестовым образцам. Таким образом, чем ниже данный показатель, тем ниже вариативность признака к проведенному преобразованию. Классификация контрольных образцов в исходном виде (без сдвигов и поворотов) при обучении классификатора на выборке объёмом 25 образцов показала результаты с точностью 96 %.

Были реализованы сдвиги тестовых образцов на 25% от собственного размера влево (вправо) и на 25% вверх (вниз). Анализ точности классификации показывает, что результаты распознавания в обоих случаях не уменьшаются и

составляют 96 %. Таким образом, предложенный метод классификации показывает свою устойчивость к сдвигам образцов. При этом детальный анализ признаков показывает, что самым неинвариантными признаками при сдвигах контрольных образцов вверх (вниз) на 25 % от собственного размера являются значения максимальных площадей пиков для всех изображений ДВП. Модули средних отклонений для них колеблются в диапазоне от 19 до 33 %. При сдвигах влево (вправо) самыми неинвариантными признаками также являются максимальные площади пиков, а модули средних отклонений изменяются от 17 до 45 %.

Общий анализ влияния сдвигов изображений на значения признаков был проведен с использованием показателя вариативности признаков OM :

$$OM_j = \frac{1}{P} \sum_{p=1}^P M_{jp}, \quad (21)$$

где M_{jp} – модуль средних отклонений j -го признака по p -му преобразованию, P – количество преобразований, примененных к признаку.

Проведенный анализ позволяет говорить о высокой инвариантности всех групп признаков, за исключением характеристик пиков, включающих в себя количество пиков, максимальные и средние площади пиков.

Для исследования устойчивости предложенного метода классификации и признаков были выполнены повороты тестовых образцов на $\pm 45^\circ$, $\pm 90^\circ$, -30° , -60° . На рисунке 23 представлены используемые классы изображений, повернутые на 45° .

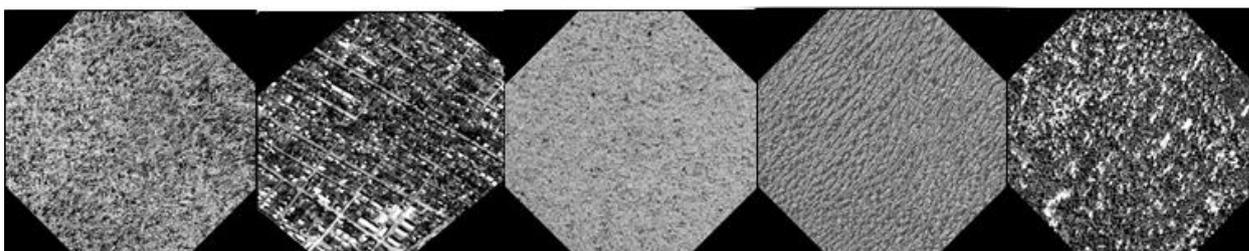


Рисунок 23 - Классы изображений, повернутые на 45°

Повороты образцов на $\pm 90^\circ$ и на -30° никак не сказались на результатах классификации, что свидетельствует о высокой устойчивости метода к этим поворотам. При повороте на $\pm 45^\circ$ точность классификации незначительно уменьшилась с 96% до 88% и 92%. А при повороте на -60° точность классификации составила 88%. Таким образом, можно говорить о высокой устойчивости исследуемого метода классификации к операции сдвига образцов.

Детальный анализ признаков с использованием значений модулей средних отклонений (20) выявил наибольшую изменчивость группы признаков, характеризующих пики и, особенно, признаки, вычисляющие максимальные площади пиков. Так, при повороте на $\pm 90^\circ$ модули средних отклонений этих признаков достигают значений 21 – 47 %. Необходимо отметить, что такие вариации значений признаков не ухудшают результаты классификации. При повороте изображений на -30° также наблюдается высокая вариативность признаков, характеризующих пики изображений ДВП. Однако, как и в предыдущем случае, на результатах классификации это не сказывается.

Поворот образцов на $\pm 45^\circ$ выявил неинвариантность стандартных отклонений для детализирующих изображений ДВП. Поворот образцов на -60° подтвердил неустойчивость этой характеристики.

Анализ влияния поворотов изображения на значения признаков с использованием показателя вариативности признаков ОМ (21) показывает наименьшую инвариантность группы признаков, характеризующей пики изображений ДВП. Такие признаки как стандартные отклонения, вычисленные для детализирующих изображений ДВП, и среднее значение по изображению диагональных деталей ДВП, также не всегда инвариантны по отношению к преобразованиям сдвига и поворота, но в некоторых случаях показывают свою эффективность при принятии решения.

Таким образом, группа признаков, характеризующая пики, показывает недостаточную инвариантность к преобразованиям сдвига и поворота. В дальнейшем рассмотрении эта группа признаков рекомендуется к исключению.

Анализ инвариантности системы признаков, строящейся из средних значений и стандартных отклонений по изображениям ДВП трех уровней вейвлет-преобразования, показывает устойчивость метода интерпретации к сдвигам и поворотам, поскольку точности классификации изменяются незначительно (от 100% до 92%).

3.4. Выводы по Главе 3

1. Исследованы две системы признаков, первая из которых состоит из средних значений и стандартных отклонений изображений ДВП, а вторая дополнена признаками, основанными на бинарном представлении изображений ДВП.

2. В результате исследований при распознавании модельных текстур из альбома Бродаца и трудноразличимых объектов на реальных данных съемочных систем RapidEye и QuickBird, выявлено, что наиболее эффективная система признаков состоит из признаков статистических показателей изображений ДВП, дополненных признаками, строящимися по бинарным массивам.

3. Анализ устойчивости и инвариантности признаков к сдвигам и поворотам выявил неустойчивость группы признаков, характеризующих пики изображений ДВП. В дальнейшем эти признаки рекомендуются к исключению из рассмотрения.

Глава 4. Вопросы реализации разработанного метода

4.1. Средства реализации и программные средства

Исследование метода интерпретации на космических снимках выполнялось с использованием доступной системы анализа снимков Opticks 4.11.0 и специально разработанного программного обеспечения определения разновидностей объектов растительности по их многозональным изображениям, написанного на языке Python. Набор написанных процедур был зарегистрирован в фонде алгоритмов и программ, получено свидетельство о регистрации программы № 2016613178 [66].

Предложенный метод был протестирован на нескольких наборах данных: снимок спутника QuickBird на район Камбарки (Удмуртия), снимок съемочной системы RapidEye на район Увинского лесхоза (Удмуртия), а также многозональные изображения, полученные с низколетящих аппаратов.

Снимок, сделанный съемочной системой QuickBird, датирован 7 мая 2004 года, охватывает территорию Камбарского района Удмуртской Республики. Снимок имеет 4 спектральных канала (синий, зелёный, красный и ближний ИК) и пространственное разрешение 2.44 м. Каналы и соответствующие им спектральные диапазоны представлены в таблице 12.

Таблица 12 - Спектральные каналы снимка QuickBird

Номер канала	Спектральный канал	Спектральный диапазон, мкм
1	Синий	0.45 – 0.52
2	Зелёный	0.52 – 0.60
3	Красный	0.63 – 0.69
4	Ближний ИК	0.76 – 0.90

Снимок съемочной системы RapidEye охватывает территорию Увинского лесхоза в Удмуртской Республике, сделан в июле 2011 года, имеет 5 спектральных каналов и обладает пространственным разрешением в 5 м.

Спектральные каналы и соответствующие им спектральные диапазоны представлены в таблице 13.

Таблица 13 - Спектральные каналы снимка RapidEye

Номер канала	Спектральный канал	Спектральный диапазон, мкм
1	Синий	0.44 – 0.51
2	Зелёный	0.52 – 0.59
3	Красный	0.63 – 0.685
4	Крайний красный	0.69 – 0.73
5	Ближний ИК	0.76 – 0.88

Основной особенностью снимков RapidEye является наличие канала «крайний красный» (red-edge), который, как утверждают разработчики, способен предоставлять дополнительную информацию, которая полезна, например, при распознавании типов растительности и при оценке их состояния. Рисунок 24 [140] представляет типичные спектральные кривые для растительности и почвы в каналах, предоставляемых RapidEye.

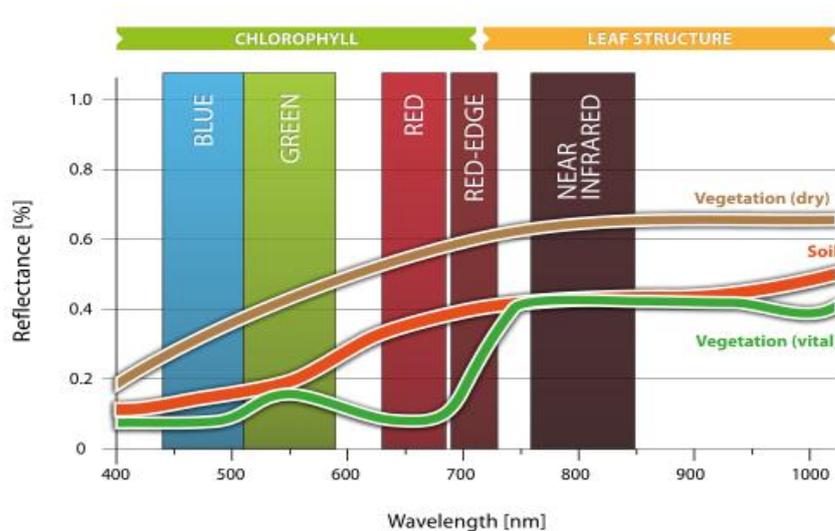


Рисунок 24 - Типичные спектральные кривые для растительности и почвы

По рисунку видно, что в крайнем красном канале отражательная способность зеленой растительности претерпевает значительный скачок в отличие от растительности, находящейся в другом состоянии.

Снимок, полученный с БПЛА Supercam S350-F, обладает пространственным разрешением 0.2 м, имеет три спектральных канала (таблица 14) и охватывает территорию Кушманского III селища (Ярский район Удмуртской Республики).

Таблица 14 - Спектральные каналы снимка, полученного с БПЛА

Номер канала	Спектральный канал	Спектральный диапазон, мкм
1	Зелёный	0.525 – 0.605
2	Красный	0.630 – 0.690
3	Ближний ИК	0.775 – 0.900

Таким образом, были рассмотрены снимки с трех различных съемочных систем, обладающих различными характеристиками. Отметим, что главной целью экспериментальной части исследования являлась проверка работоспособности метода на материалах разных съемочных систем с разными пространственным, спектральным и радиометрическим разрешением. То есть, главным условием являлось разнообразие характеристик снимков, а не их количество.

4.2. Классификация объектов растительности по данным съемочной системы QuickBird

Первый набор данных, на котором происходило исследование объектов с использованием предложенного метода интерпретации, состоял из изображений объектов лесной растительности на снимке QuickBird, фрагмент которого приведен на рисунке 25.

Было выбрано 6 классов объектов, для которых имеются участки, обеспеченные надежной справочной информацией о классе объекта: хвойный лес (класс I), лиственный лес (класс II), смешанный лес (класс III), старые вырубки (класс IV), вырубки без поросли (класс V), лес с остатками снега (класс VI). На исследуемой территории Камбарского района Удмуртской Республики хвойный лес представлен массивами соснового леса. Лиственный лес включает берёзу и

липу, а смешанный лес состоит из деревьев и лиственных, и хвойных пород. Старые вырубки представляют собой участки вырубленных лесов, которые в течение времени были покрыты порослью березы. Вырубки без поросли – недавно вырубленные участки лесов, не успевшие покрыться древесной растительностью. Поскольку снимок сделан в мае, то на некоторых фрагментах изображения отчетливо видны остатки снега, что позволило сформировать ещё один класс объектов.



Рисунок 25 - Фрагмент исходного снимка QuickBird в естественных цветах

Пространственное разрешение в 2.5 м находится на границе разрешения элементов структуры представленных классов. Таким образом, исследование на таких классах объектов позволит нам судить о возможностях предложенного метода при классификации трудноразличимых (в смысле Живичина) объектов.

На рисунке 26 представлено по одному эталонному образцу каждого из описанных классов, а на рисунке 27 – их спектральные кривые.

Вид спектральных кривых позволяет говорить о том, что все рассматриваемые объекты характеризуются тем, что наибольшая отражательная способность приходится на 2 и 4 каналы, соответствующие зелёному и ближнему ИК диапазонам. Наибольший разброс отражательной способности проявляется в диапазоне ближнего ИК диапазона.

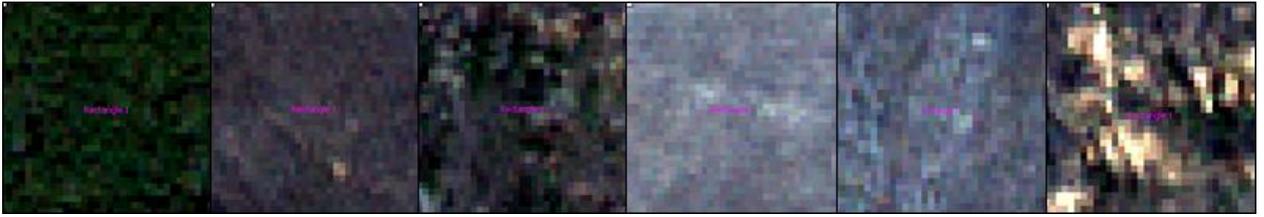


Рисунок 26 - Образцы, представляющие последовательно классы хвойных, лиственных, смешанных лесов, заросших вырубок, свежих вырубок и лесов с остатками снега

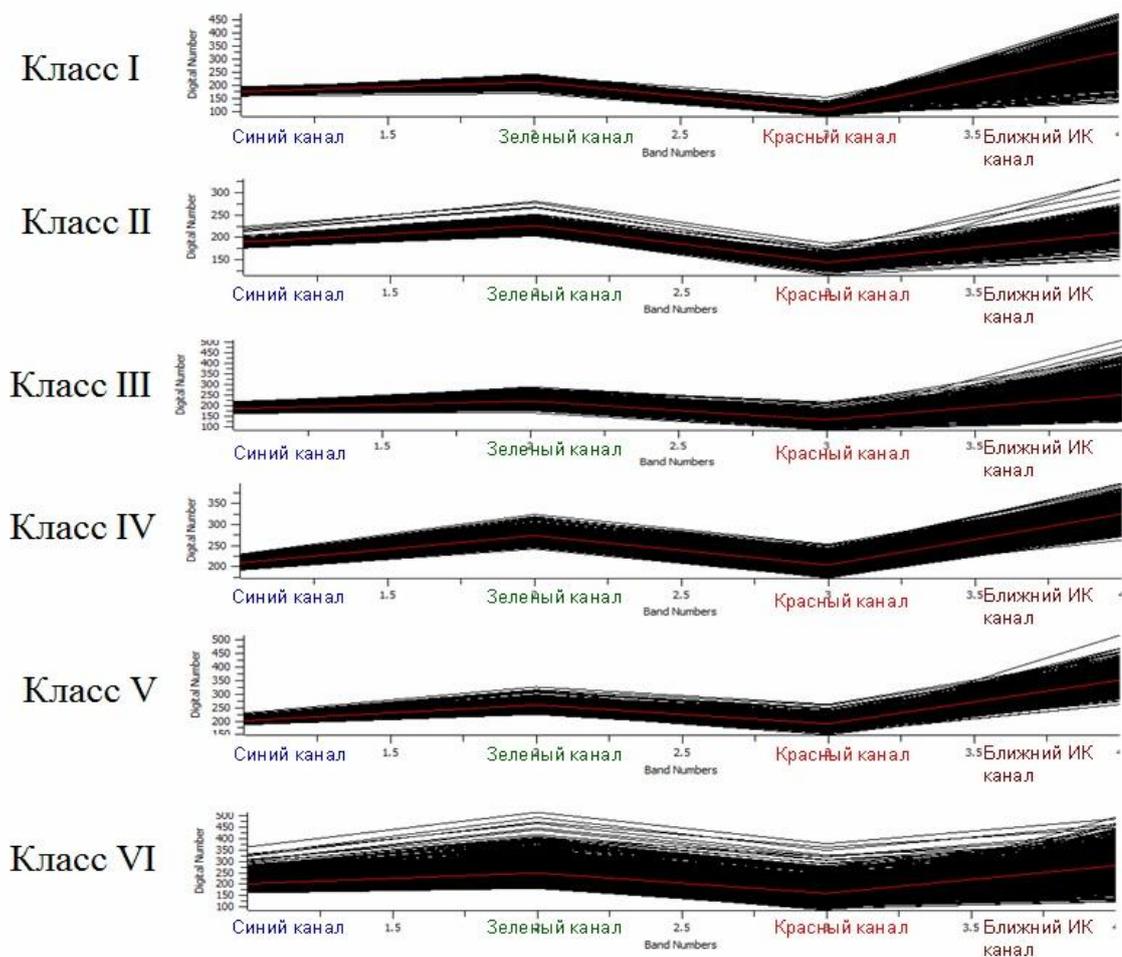


Рисунок 27 - Спектральные кривые, построенные по образцам, представленным на рисунке 26

Похожие между собой формы спектральных кривых для этих объектов позволяют говорить о том, что использование попиксельной классификации объектов с комбинацией каналов снимка на основе вегетационных индексов, не будет являться эффективным.

Проведена классификация описанного набора данных съемочной системы QuickBird разработанным методом, параметры которого были установлены исходя из исследований в главе 3. Система признаков состоит из статистических показателей изображений ДВП Шеннона-Котельникова первого уровня, дополненных признаками, строящимися по бинарным массивам без характеристик пиков. Общее количество признаков составило 112. Объем обучающей выборки составил 30 образцов, а контрольной – 60. Обучающая и контрольная выборка были выбраны таким образом, чтобы эталонные образцы, осуществляющие контроль и обучение не пересекались. В результате точность классификации отдельных классов оказалась не ниже 90 %, что отображено в таблице 15. А общая точность составила 98 %, что свидетельствует об эффективности разработанного метода при классификации трудноразличимых площадных объектов местности.

Таблица 15. Результаты классификации объектов лесной растительности на снимке QuickBird (OT=98 %, K=0.98)

–	Класс I	Класс II	Класс III	Класс IV	Класс V	Класс VI
Вероятность успешной классификации, %	100	90	100	100	100	100

Кроме того, был проведен эксперимент по классификации того же набора данных снимка QuickBird с использованием наиболее простого по своим характеристикам метода. Так, на этапе формирования векторов признаков производилось одноуровневое вейвлет-преобразование Хаара, в результате чего было получено 4 изображения ДВП. В качестве минимального набора признаков использовались среднее значение и стандартное отклонение, рассчитанные по всем каналам всех изображений ДВП. То есть, размерность пространства признаков составляла 32. На этапе принятия решения использовался простейший

из известных классификатор минимального расстояния с мерой Евклида. Полученные результаты приведены в таблице 16.

Таблица 16 - Результаты классификации в пространстве признаков, построенных на основе одноуровневого вейвлет-преобразования Хаара

–	Класс I	Класс II	Класс III	Класс IV	Класс V	Класс VI
Вероятность успешной классификации, %	90	90	100	100	80	90

Полученные результаты показывают, что использование признаков, построенных на основе даже простейшего вейвлет-преобразования Хаара, и применение классификатора минимального расстояния позволяет классифицировать трудноразличимые объекты растительности с вероятностью распознавания каждого класса, превышающей 80%.

4.3. Классификация объектов лесной растительности по данным съемочной системы RapidEye

Другим набором данных, к которому был применен предложенный метод интерпретации, выступает снимок съемочной системы RapidEye, фрагмент которого представлен на рисунке 28.

Для проведения исследования на снимке было выделено шесть классов объектов лесной растительности, описание которых представлено в таблице 17. На рисунке 29 представлены образцы исследуемых классов в натуральных цветах, а на рисунке 30 – те же образцы, где в раскладке RGB вместо красного канала взят ближний инфракрасный. Сравнивая рисунки 29 и 30 нетрудно заметить, то представители, например 1 и 2 класса, на рисунке 29 визуальнo практически неразличимы, что нельзя сказать о тех же образцах, с использованием канала БИК, что, подтверждает эффективность использования мультиспектральных данных. Поскольку выбранные классы являются трудноразличимыми в смысле

Живичина (см. п.1.1), то вероятность успешного визуального распознавания таких объектов не превышает 0.35.



Рисунок 28 - Фрагмент исходного снимка RapidEye

Таблица 17 - Исследуемые классы объектов

№ п/п	Объем тестов	Название класса	Описание класса
1	20	Смешанный лес	Лес, содержащий деревья березы и сосны
2	20	Лиственный лес-1	Лес, содержащий деревья березы и осины
3	21	Хвойный лес	Сомкнувшиеся культуры, состоящие из деревьев ели
4	21	Лиственный лес-2	Лес, содержащий деревья липы, березы и осины
5	20	Молодой хвойный лес	Посадки хвойного елового леса
6	22	Вырубки с подростом	Вырубленные участки лесов, покрытые кустарниковой растительностью и

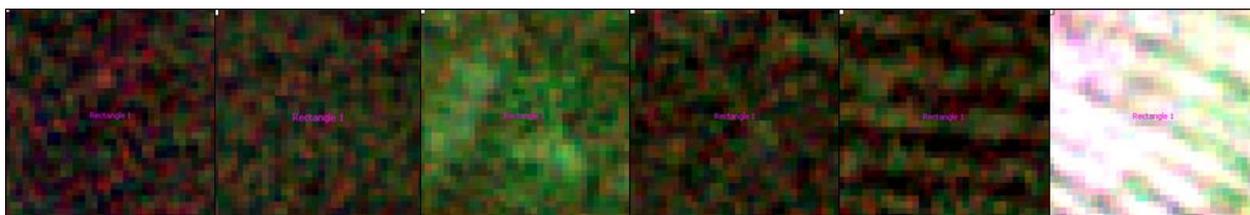


Рисунок 29 - Образцы, представляющие соответственно смешанный лес; лиственный лес из березы и осины; хвойный лес; лиственный лес из липы, березы и осины; молодой хвойный лес; вырубки с подростом

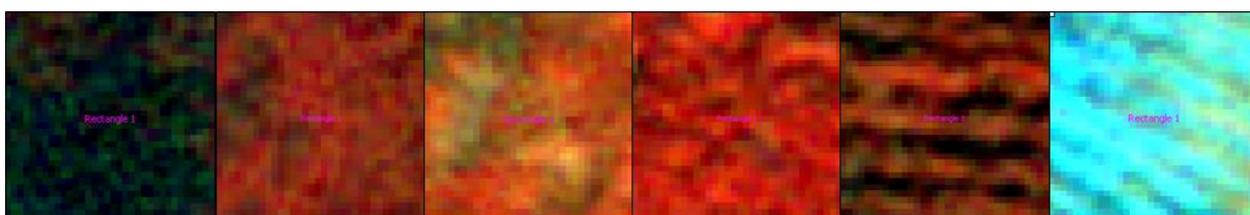


Рисунок 30 - Синтез каналов. Ближний инфракрасный (БИК) - зеленый - синий

Результат применения разработанного метода интерпретации с параметрами, выбранными в главе 3, представлены в таблице 18. Общая точность в 93 % свидетельствует об эффективности разработанного метода при классификации изображений объектов лесной растительности на снимке RapidEye с разрешением в 5 м.

Таблица 18. Результаты классификации объектов лесной растительности на снимке RapidEye (OT=93 %, K=0.91)

–	Класс I	Класс II	Класс III	Класс IV	Класс V	Класс VI
Вероятность успешной классификации, %	95	95	95	90	85	95

Однако, при классификации с помощью предложенного метода, который принимает решение на основе голосования признаков, необходимо определиться с таким задаваемым параметром как количество сегментов для разбиения диапазонов принимаемых значений признаков (см. п.2.2).

В базовом варианте параметр «количество сегментов» был взят равным 6. При исследовании зависимости результатов от данного параметра были проведены серии экспериментов с параметром «количество сегментов» равным 4, 8, 10 и 12, одновременно с этим варьировался уровень ДВП от 1 до 3. Полученные оценки результатов классификации в виде общей точности (ОТ) и коэффициента каппа (К) с использованием разных вейвлет-функций приведены в табл. 19 – 21.

Таблица 19 - Результаты классификации с разными значениями параметра «количество сегментов» для вейвлета Хаара

Число сегментов	1 уровень ДВП		2 уровень ДВП		3 уровень ДВП	
	ОТ	К	ОТ	К	ОТ	К
4	89%	0.86	90%	0.87	92%	0.90
6	90%	0.87	90%	0.87	90%	0.88
8	85%	0.82	90%	0.87	92%	0.90
10	85%	0.82	90%	0.88	92%	0.90
12	86%	0.84	89%	0.86	86%	0.84

Таблица 20 - Результаты классификации с разными значениями параметра «количество сегментов» для симлета

Число сегментов	1 уровень ДВП		2 уровень ДВП		3 уровень ДВП	
	ОТ	К	ОТ	К	ОТ	К
4	90%	0.87	93%	0.91	91%	0.89
6	93%	0.91	89%	0.86	92%	0.90
8	89%	0.86	90%	0.88	91%	0.89
10	85%	0.83	89%	0.86	90%	0.88
12	77%	0.73	87%	0.85	90%	0.87

Таблица 21 - Результаты классификации с разными значениями параметра «количество сегментов» для вейвлета Шеннона-Котельникова

Число сегментов	1 уровень ДВП		2 уровень ДВП		3 уровень ДВП	
	ОТ	К	ОТ	К	ОТ	К
4	85%	0.83	88%	0.85	88%	0.85
6	93%	0.91	89%	0.86	90%	0.87
8	94%	0.92	94%	0.93	95%	0.94
10	94%	0.93	95%	0.94	95%	0.94
12	95%	0.94	98%	0.97	97%	0.96

Обобщая исследования зависимости результатов классификации от параметров вейвлет-преобразования и метода принятия решения, можно сделать выводы для трех вейвлет-функций. При работе с признаками, построенными на основе вейвлет-преобразования Хаара, с увеличением уровня ДВП происходит определенный рост показателей точности, что представлено на рисунке 31(а). Это характерно для всех рассматриваемых значений параметра «количество сегментов», кроме числа сегментов равного 12, при котором наблюдается существенный спад оценок точности. Для симплета (рисунок 31(б)) изменение уровня ДВП и количества сегментов не приводит к существенным изменениям в результатах. Результаты, полученные с признаками, построенными с использованием вейвлета Шеннона-Котельникова (рисунок 31(в)), показывают, что при увеличении числа сегментов происходит рост показателей точности. Наиболее высокие значения общей точности и коэффициента К (ОТ=98%, К=0.97) получены при 12 сегментах и двухуровневом ДВП Шеннона-Котельникова.

В результате исследований различных параметров вейвлет-преобразования и предложенного классификатора был получен результат с общей точностью 98%, который позволяет говорить о высокой эффективности предложенного метода. Этот результат был получен при работе с системой признаков, построенной на основе изображений ДВП, полученных в результате двухуровневого вейвлет-

преобразования Шеннона-Котельникова. Система признаков включала в себя средние значения и стандартные отклонения, рассчитанные по изображениям ДВП. При этом параметр классификатора «количество сегментов» был равен 12.

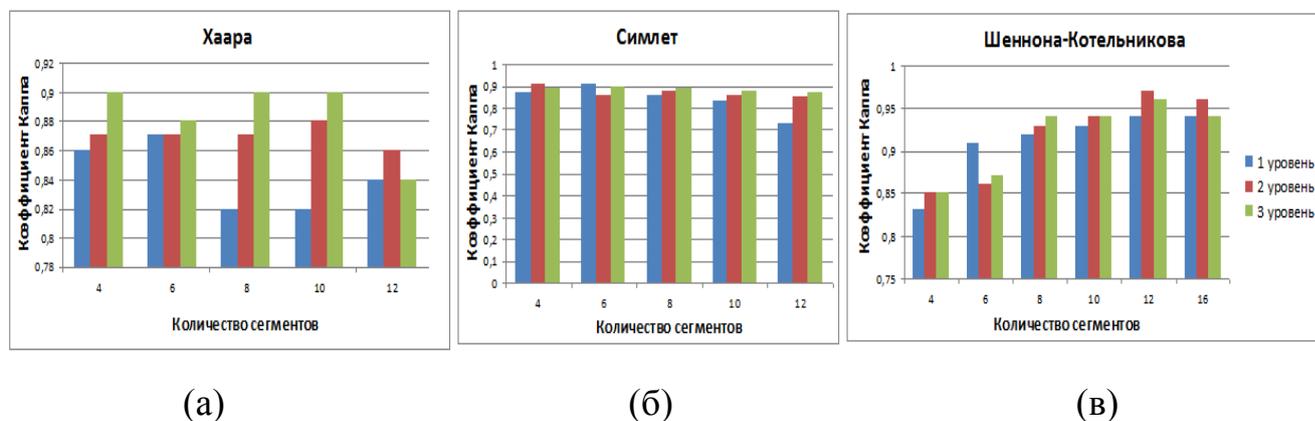


Рисунок 31 - Графики зависимости коэффициента каппа от уровня ДВП и количества рассматриваемых сегментов (синий цвет - 1 уровень ДВП, красный цвет - 2 уровня ДВП, зеленый цвет - 3 уровня ДВП)

Использование других материнских вейвлет-функций также позволило достичь довольно высоких показателей точности. В таблице 22 представлены наилучшие комбинации параметров вейвлет-преобразования и метода классификации и соответствующие им результаты для трех вейвлет-функций.

Анализ полученных результатов позволяет сделать следующие выводы. Признаки, полученные на втором и третьем уровнях вейвлет-преобразования, вносят дополнительную полезную информацию для разделения классов. Для вейвлета Хаара более полезными является одновременное использование признаков трех уровней ДВП, при этом количество сегментов в диапазоне от 4 до 10 дает сходные результаты. При работе с симлетом целесообразно строить признаки на первом уровне ДВП, а классификацию проводить с количеством сегментов от 4 до 6. Наиболее эффективный набор параметров метода классификации – это вейвлет Шеннона-Котельникова, 2 уровня вейвлет-преобразования и 12 сегментов разбиения диапазонов значений признаков.

Таблица 22 - Наилучшие параметры вейвлет-преобразования и метода классификации

Вейвлет-функция	Хаара			Симлет			Шэннона-Котельникова		
	1	2	3	1	2	3	1	2	3
Уровень ДВП	1	2	3	1	2	3	1	2	3
Число сегментов	6	4-10	4-10	6	4	6	12-16	12	2
ОТ	90%	90%	92%	93%	93%	92%	95%	98%	97%
К	0.87	0.87	0.90	0.91	0.91	0.90	0.94	0.97	0.96

Выполнено сравнение результатов разработанного метода интерпретации космических снимков площадных объектов местности с другими известными реализациями. В таблице 23 приведены результаты классификации в виде общей точности, характеристики снимков, а также наборы рассматриваемых классов. Таблица 23 включает в себя только те работы из Приложения А, которые сопоставимы по характеристикам снимков и по составу классов объектов с настоящей работой. Строки таблицы с номерами 5 и 6 соответствуют исследованиям, представленным в п. 4.2 и п. 4.3.

Таблица 23. Результаты исследований, сопоставимых по набору классов и разрешению используемых снимков

Год, ссылка	Признаки	Метод	ОТ	Набор классов	Разрешение снимка
1 2004, [110]	Спектральные и текстурные признаки	Метод максимального правдоподобия	83 %	9 классов: густой лес; лес-кустарник; густой кустарник; разрозненные деревья; травянистая растительность или сорняки; зерновые или пастбища; не вспаханные земли; жилые районы; море.	4 канала, 2.4 м

Продолжение таблицы 23

Год, ссылка	Признаки	Метод	ОТ	Набор классов	Разрешение снимка
2 2005, [38]	Спектральные признаки и признаки Харалика	Метод ближайшего соседа	73 %	6 классов: кедр; кипарис; лиственница; смешанные леса (хвойные); смешанные леса (широколиственные деревья); широколиственные леса.	4 канала, 2.4 м (0.6 м)
3 2012, [106]	Спектральные признаки	Случайный лес	83 %	8 классов: лес-1; лес-2; фруктовый сад; трава; почва; дороги; городская структура; тени.	4 канала, 2.4 м
4 2015, [108]	Спектральные признаки	Итеративная иерархическая модель классификации	78 %	13 классов: жилые районы; коммерческие районы; промышленные; транспорт; смешанные городские земли; пахотные земли; садовые; лиственные леса; хвойные леса; смешанные леса; песчаные земли; скалы; детские площадки.	0.3 м
5	Комбинированная система признаков, основанная на вейвлет-преобразовании	Метод принятия решений, основанный на вычислении оценок	92 %	6 классов: хвойный лес; лиственный лес; смешанный лес; вырубки с порослью; вырубки без поросли; лес с остатками снега.	4 канала, 2.4 м
6	Комбинированная система признаков, основанная на вейвлет-преобразовании	Метод принятия решений, основанный на вычислении оценок	98 %	6 классов: смешанный лес (береза, сосна); лиственный лес-1 (береза, осина); хвойный лес (ель, сомкнувшиеся культуры); лиственный лес-2 (липа, береза, осина); молодой хвойный лес (ель, посадки); вырубки с подростом.	5 каналов, 5 м

Анализ таблицы 23 позволяет сделать вывод о том, что разработанный метод интерпретации космических снимков площадных объектов местности, на снимках с разным спектральным и пространственным разрешением показывает результаты, превосходящие по своей точности другие аналогичные исследования. Отметим, что для достижения наиболее высоких показателей точности параметры метода классификации выбирались в зависимости от характеристик снимка.

4.4. Классификация объектов растительности по изображениям, полученным с низколетящего беспилотного летательного аппарата

В целях исследования возможностей разработанного метода для обработки снимков высокого пространственного разрешения, полученных с низколетящего аппарата, выполнено исследование, описанное в настоящем разделе.

Исходные снимки были получены в трех спектральных каналах – зелёный, красный, ближний ИК. Для проверки эффективности работы предложенного метода было выбрано 4 класса объектов: 1. Высокая трава, редкие кустарники; 2. Скошенная трава; 3. Сухая трава; 4. Комплекс объектов растительности (трава, сухая трава, скошенная трава). На рисунке 32(а) приведен исходный снимок, представленный в виде изображения в цветовой модели R – красный, G – зелёный, B – ближний ИК.

При обучении метода использовалось по 5 образцов каждого класса, при тестировании – по 15 образцов. Все образцы имели размер в пикселях 64×64. Обучающая и тестовая выборка не пересекались. Разбиение диапазонов принимаемых значений признаков проводилось на 6 равных сегментов, при формировании признаков использовалось одноуровневое вейвлет-преобразование Шеннона-Котельникова. Полученные результаты представлены в виде матрицы ошибок в таблице 24.

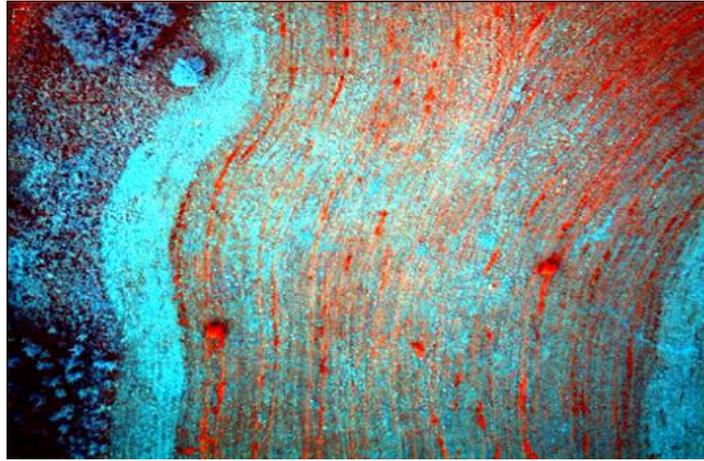


Рисунок 32 - Изображение, полученное с помощью снимков с низколетящего аппарата

Анализируя матрицу ошибок, можно говорить о том, что всего методом классификации было допущено 2 ошибки: образец второго класса был ошибочно отнесен к классу №4, а другой образец класса №4 ошибочно был отнесен к классу №3.

Полученные общая точность и коэффициент каппа свидетельствуют об эффективности предложенного метода при классификации объектов растительности на многозональных снимках высокого пространственного разрешения.

Таблица 24. Матрица ошибок (Общая точность = 97 %, коэффициент каппа=0.96)

Номер класса	1	2	3	4	Сумма строки	Точность пользователя
1	15				15	100 %
2		14			14	100 %
3			15	1	16	94 %
4		1		14	15	93 %
Сумма столбца	15	15	15	15	60	–
Точность разработчика	100 %	93 %	100 %	93 %	–	–

4.5. Использование мультиспектральных данных высокого пространственного разрешения для обнаружения областей местности с характерными свойствами

В настоящее время в связи с улучшением качества материалов многозональной съемки и повышением их доступности существенно увеличился круг решаемых задач. Достаточно большую группу таких задач представляют задачи обнаружения на поверхности Земли областей, которые по некоторым свойствам, интересующим потребителя, отличаются от окружения. Такими областями могут быть, например, зоны растительности, пораженные вредителями, засоленные участки полей, территории, под землей которых находятся бывшие свалки, территории с остатками земельных работ и т.п. Поскольку различия в свойствах таких областей проявляются в характеристиках растительности, а следовательно, и на снимках ДЗЗ, то использование мультиспектральных данных, получаемых в результате дистанционного зондирования Земли, представляется перспективным и целесообразным для обнаружения объектов, ненаблюдаемых на поверхности Земли. Преимущества данных ДЗЗ в таких задачах заключаются в отсутствии непосредственного контакта с исследуемыми объектами и возможности охвата больших территорий, что существенно снижает затраты материальных и трудовых ресурсов.

Для исследования возможностей использования мультиспектральных данных при решении задачи обнаружения территорий со значительной мощностью гумусированного слоя (такие территории очень перспективны с точки зрения поиска археологических памятников), был использован снимок, полученный с низколетящего БПЛА (рисунок 33(а)). Снимок был сделан в ближнем инфракрасном (БИК) диапазоне ($0.775 \pm 0.005 - 0.900 \pm 0.005$ (μm)) и обладает пространственным разрешением 0.2 м.

В качестве эталонной карты был использован фрагмент изображения, полученного в результате геофизических исследований той же территории

(рисунке 33(б)). Красным цветом выделены участки большей мощности гумусированного слоя.

Для того чтобы адаптировать ранее разработанную систему признаков под поставленную задачу, используется базовая линия настройки метода, которая нанесена на рисунке 33 (б). Базовая линия ориентирована в направлении юго-восток – северо-запад и пересекает разнохарактерные участки: разрушенного культурного слоя на мысовой части поселения; сохранившегося слоя на территории поселения; линию укреплений (вал-ров), сглаженную распашкой, а также участок за границей поселений, на котором культурный слой практически отсутствует. Такое расположение обеспечивает репрезентативный набор данных, необходимый для настройки и апробации метода анализа мультиспектральных данных на основе вейвлет-преобразования.

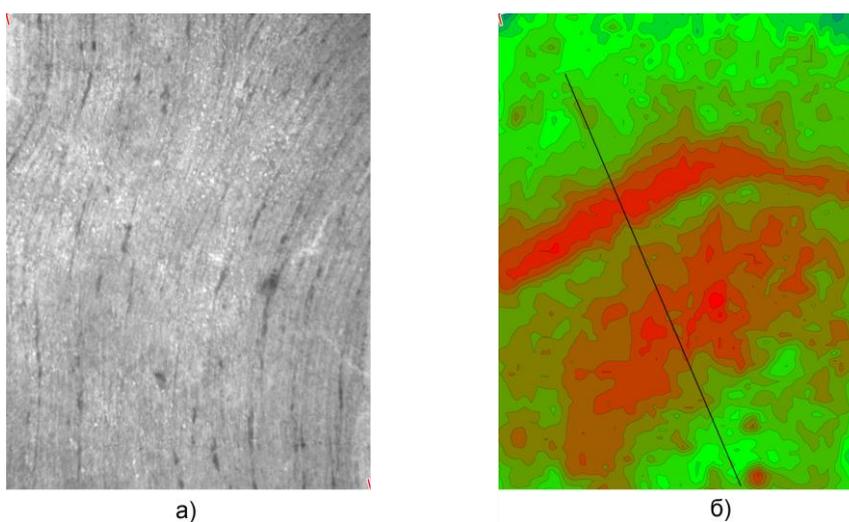


Рисунок 33 – Исходные данные: а) снимок, полученный с БПЛА в БИК диапазоне; б) изображение, полученное в результате геофизических исследований, и нанесённый на него профиль

Из предыдущих исследований было выявлено, что для классификации объектов растительности, наилучшей вейвлет-функцией выступает вейвлет Шеннона-Котельникова, а система признаков может быть сформирована из средних значений и стандартных отклонений, рассчитанных по изображениям, полученным в результате двумерного дискретного вейвлет-преобразования

(ДВП). Исследовались признаки, строящиеся на первом уровне ДВП (8 признаков). Предлагаемый метод построения карты областей мощного почвенного слоя, характеризующиеся интенсивными процессами почвообразования, предполагает следующие действия. Вдоль базовой линии на изображении БИК рассчитываются признаки, путём сканирования окном размером 16×16 пикселей, проведения одноуровневого ДВП для этого окна и расчета среднего значения соответствующего изображения ДВП. Для отбора наиболее информативных характеристик на данных ДЗЗ проводится сравнение с данными эталонного изображения. Для этого вдоль базовой линии на эталонном изображении строится профиль значений. Далее исследуются коэффициенты корреляции рассчитанных признаков и соответствующих пикселей на эталонном изображении (таблица 25).

Таблица 25 - Коэффициенты корреляции между значениями признаков и значениями пикселей на эталонном изображении, рассчитанных вдоль базовой линии

Признак	Коэффициент корреляции
Среднее значение изображения аппроксимации, вейвлет Шеннона-Котельникова	0.388
Среднее значение изображения горизонтальных деталей, вейвлет Шеннона-Котельникова	-0.600
Среднее значение изображения вертикальных деталей, вейвлет Шеннона-Котельникова	-0.498
Среднее значение изображения диагональных деталей, вейвлет Шеннона-Котельникова	0.202
Среднее значение изображения аппроксимации, вейвлет Хаара	-0.464
Среднее значение изображения горизонтальных деталей, вейвлет Хаара	0.102
Среднее значение изображения вертикальных деталей, вейвлет Хаара	-0.010
Среднее значение изображения диагональных деталей, вейвлет Хаара	0.017

Выбраны два признака с наибольшими значениями модулей коэффициентов корреляции – средние значения, рассчитанные по изображениям горизонтальных (0.600) и вертикальных деталей (0.498).

Поскольку значения рассматриваемых признаков, а также значения пикселей эталонного изображения имеют отличные диапазоны, то была проведена нормализация значений признаков по изображениям ДВП и яркостей пикселей по эталонному изображению (рисунок 34).

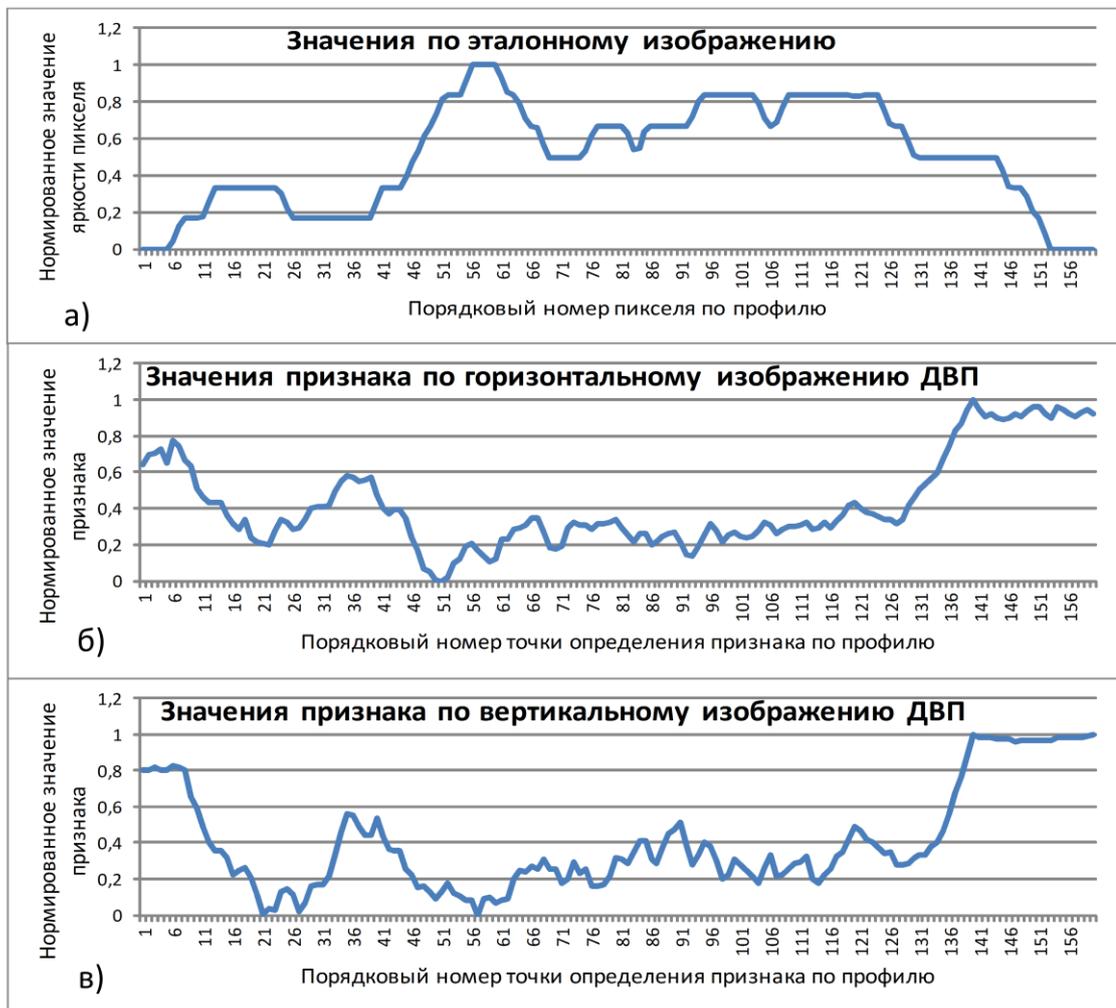


Рисунок 34 - Значения выбранных признаков и пикселей эталонного изображения

Для объединения отобранных признаков (средние значения по вертикальным и горизонтальным изображениям одноуровневого ДВП) в один показатель было использовано среднее значение этих признаков. Результат объединения признаков в дальнейшем будем называть индикатором характерной

области. Так как значения коэффициентов корреляции двух рассмотренных признаков отрицательны, проведено преобразование $p_{ij} \rightarrow 1 - p_{ij}$, $p_{ij} \in [0,1]$. В результате график изменения значений индикатора по профилю принял вид, представленный на рисунке 35 зелёным цветом. Коэффициент корреляции значений индикатора и яркостей пикселей эталонного изображения вдоль базовой линии по эталонному изображению составляет 0.60.

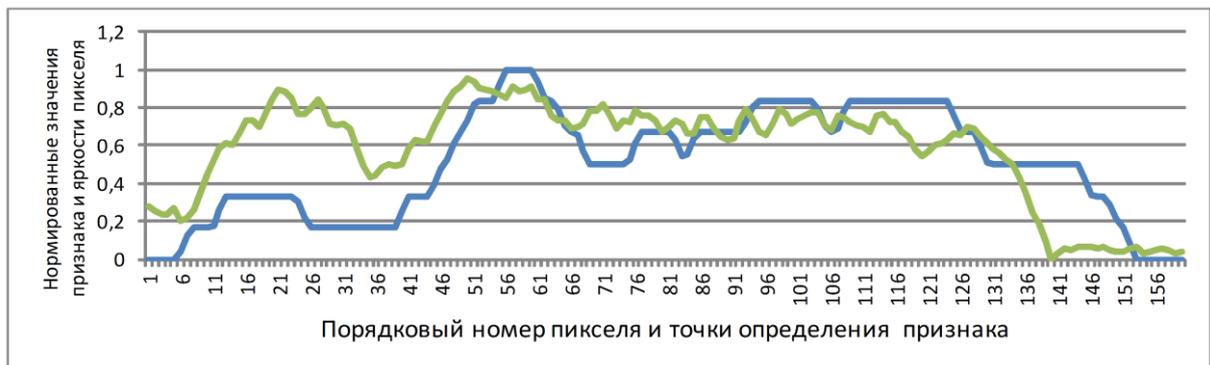


Рисунок 35 - Значения яркостей пикселей вдоль профиля по «эталонному» изображению (синяя линия), значения индикатора характерной области вдоль профиля (зелёная линия)

Предложенный индикатор характерной области хорошо коррелирует с эталонными данными. Процедура преобразования была применена к исходному изображению БИК диапазона. Проведено нормирование изображений ДВП и эталонного изображения. Для получения индикатора рассчитывались средние значения соответствующих пикселей в полученных изображениях ДВП. То есть, пусть H – это матрица пикселей изображения горизонтальных деталей, V – матрица пикселей изображения вертикальных деталей, n – количество строк в H и V , m – количество столбцов в H и V . Тогда значения пикселей выходного изображения G будут вычисляться по формуле:

$$g_{ij} = \frac{h_{ij} + v_{ij}}{2}, \quad i = \overline{1, n}; \quad j = \overline{1, m}.$$

Поскольку в результате двумерного ДВП, получаемые изображения уменьшаются в размерах, то для сопоставления полученных данных с эталонным изображением была проведена локальная интерполяция изображения G линейной функцией.

Результат применения предложенного метода к изображению БИК представлен на рисунок 36 (справа). Темные участки на полученном изображении представляют области с большей мощностью гумусированного слоя, и эти области соответствуют красным участкам на изображении данных электроразведки (рисунок 36, слева). Эллипсами на рисунке 36 околтурены две ярко выраженные характерные области гумусированного слоя на данных электроразведки и данных ДЗЗ. Сопоставление формы и размеров этих областей показывает высокую степень соответствия значений индикатора и геофизических данных.

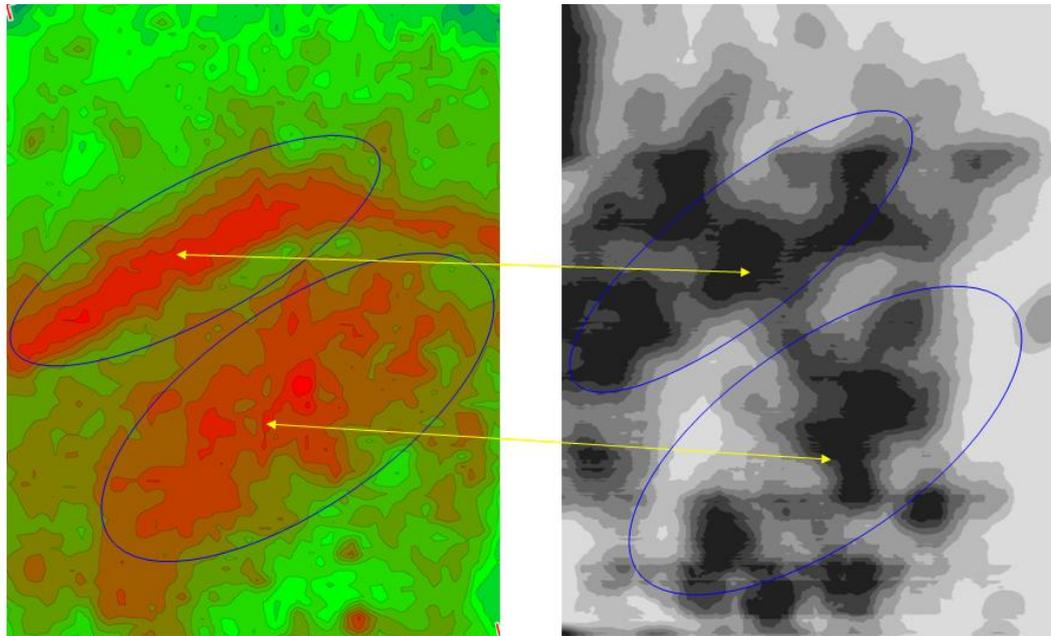


Рисунок 36 - Карты областей с характерными свойствами, полученные по данным электроразведки (слева) и мультиспектральным данным ДЗЗ (справа)

Визуальное сопоставление полученного изображения с эталонным изображением позволяет говорить о том, что мультиспектральные данные, получаемые с БПЛА, могут служить эффективным инструментом в задачах

определения областей местности с характерными свойствами (например, территорий со значительной мощностью гумусированного слоя).

Отметим, что при проведении аналогичного исследования по снимку, полученному в ранний период вегетации, был достигнут также довольно высокий уровень соответствия эталонных данных и данных, полученных в результате применения разработанного метода. Однако, наибольшая корреляция достигалась при рассмотрении зеленого спектрального канала снимка. Таким образом, разработанный метод выявления областей местности с характерными свойствами обладает свойством универсальности относительно вариаций вегетационного состояния растительности при использовании мультиспектральных данных.

4.6. Выводы по Главе 4

1. Разработанный метод интерпретации применен к задачам распознавания данных разных съемочных систем.

2. При классификации 6 классов объектов растительности на снимке QuickBird точности классификации для каждого класса не ниже 80 %.

3. Применение разработанного метода интерпретации к распознаванию 6 классов трудноразличимых объектов лесной растительности на снимке RapidEye позволило получить максимальную точность в 98 %.

4. Классификация 4 классов объектов растительности на снимке сверхвысокого разрешения, полученного с БПЛА, также показала высокую точность и составила 97 %.

5. Разработан и применен метод выявления областей местности с характерными свойствами на примере задачи обнаружения территорий с наибольшей мощностью гумусированного слоя земли.

Заключение

В работе получены следующие результаты:

1) исследованы существующие методы интерпретации многозональных космических снимков земной поверхности с анализом их преимуществ и недостатков для различных видов площадных объектов. Установлена необходимость разработки метода, способного с высокой точностью классифицировать трудноразличимые площадные объекты местности на снимках высокого разрешения;

2) исследованы существующие подходы к формированию признаков, что позволило сделать вывод, что для полного описания объектов, обладающих спектральными и структурными особенностями, построение системы признаков должно основываться на вейвлет-преобразовании. Должен быть предусмотрен этап выбора наиболее информативных признаков;

3) разработана система признаков, основанная на вейвлет-преобразовании, способная учитывать частотные и пространственные особенности изображения;

4) разработан метод принятия решения, относящийся к разделу алгоритмов вычисления оценок, главными особенностями которого является дискретизация значений признаков и возможность оценки значимости признаков;

5) исследована зависимость результатов классификации от параметров вейвлет-преобразования: вейвлет-функция, уровень преобразования; и параметра метода принятия решений: количество сегментов;

6) проведены исследования по модельным изображениям текстур из альбома Бродаца, которые позволили сформировать эффективную систему признаков;

7) проведены исследования с использованием снимков нескольких съемочных систем при решении задач распознавания объектов растительности. Полученные результаты показывают, что точность классификации с использованием предложенного метода превышает показатель общей точности в 80 %, что является преимуществом по сравнению с известными результатами

классификации в сравнимых условиях. Кроме того, в ходе исследований разработанного метода достигнуты результаты с максимальной точностью в 98 %;

8) выполненные исследования подтвердили эффективность метода для мультиспектральных данных нескольких съемочных систем с различным пространственным, спектральным и радиометрическим разрешением;

9) предложен и реализован метод использования разработанной системы признаков для выявления областей местности с характерными свойствами на мультиспектральных данных, полученных с БПЛА. Результаты, полученные при обнаружении территорий перспективных с точки зрения наличия археологических памятников, показали высокую степень соответствия со справочными данными;

10) перспективы развития разработанного метода по мнению автора заключаются в исследовании возможностей применения этого метода для решения задач, связанных с анализом разновременных мультиспектральных данных на одну и ту же территорию.

Список сокращений и условных обозначений

БПЛА - беспилотный летательный аппарат

ВИ - вегетационный индекс

ДВП - дискретное вейвлет-преобразование

ДЗЗ - дистанционное зондирование Земли

ИК - инфракрасный

ОРГ - оптимальная разделяющая гиперплоскость

ОТ - общая точность

ТП - точность пользователя

ТР - точность разработчика

ФВЧ - фильтр высоких частот

ФНЧ - фильтр низких частот

Список литературы

1. Аковецкий, В. И. Дешифрирование снимков / В. И. Аковецкий. – М.: Недра, 1983. – 374 с.
2. Андреев, Г. А. Анализ и синтез случайных пространственных текстур / Г. А. Андреев, О. В. Базарский, А. С. Глауберман, А. И. Колесников, Ю. В. Коржик, Я. Л. Хлявич // Зарубежная радиоэлектроника. – 1984. – №2. – С. 3-33.
3. Антощук, С. Г. Система распознавания текстурных изображений при экологическом мониторинге / С. Г. Антощук, Н. А. Сербина // Искусственный интеллект. – 2002. – №4. – С. 406-413.
4. Аркадьев, А. Г. Обучение машины распознаванию образов / А. Г. Аркадьев, Э. М. Браверман. – М.: Наука, 1964. – 112 с.
5. Афанасьев, Н. Ф. Математические методы в геологическом дешифрировании аэроснимков / Н. Ф. Афанасьев, К. М. Петров, А. В. Теосев и др. – М.: Недра, 1981. – 280 с.
6. Ахметшин, А. М. Статистическая классификация текстурных изображений методом обобщенного спектрального анализа в базисе Грамма-Шмидта / А. М. Ахметшин, В.А. Бойко, Б.С. Бусыгин // Радиоэлектронные и компьютерные системы. – 2005. – №2(10). – С. 108-114.
7. Ахметшин, А. М. Автокорреляционная функция преобразования Радона как инвариантная к влиянию поворота характеристика изображения текстуры / А. М. Ахметшин, А. А. Степаненко // Искусственный интеллект. – 2011. – №4. – С. 152-158.
8. Баранов, Ю. Б. Рынок данных ДЗЗ в России / Ю. Б. Баранов // Пространственные данные. – 2005. – №3. – С. 32-46.
9. Богомоллов, Л. А. Дешифрирование аэроснимков / Л. А. Богомоллов. – М.: Недра, 1976. – 145 с.
10. Большая Российская энциклопедия: В 35 т. / отв. ред. С. Л. Кравец. – М.: Большая Российская энциклопедия, 2016. – 338 с.

11. Борзов, С. М. Исследование эффективности пространственных признаков при классификации спутниковых изображений различного разрешения / С. М. Борзов, А. О. Потатуркин // Вестник НГУ. – 2013. – №3 (10). – С. 58-65.
12. Вагин, В. Н. Достоверный и правдоподобный вывод в интеллектуальных системах / В. Н. Вагин, Е. Ю. Головина, А. А. Загорянская, М. В. Фомина. – М.: Физматлит, 2004. – 704 с.
13. Вапник, В. Н. Машины, обучающиеся распознаванию образов // Алгоритмы обучения распознавания образов; Под ред В. Н. Вапника. – М.: Советское радио, 1973. – С. 5 – 8.
14. Вапник, В. Н. Теория распознавания образов / В. Н. Вапник, А. Я. Червоненкис. – М.: Наука, 1974. – 416 с.
15. Вайнцвайг, М. Н. Алгоритм обучения распознаванию образов «кора» / М. Н. Вайнцвайг // Алгоритмы обучения распознаванию образов. – М.: Советское радио, 1973. – С. 110-116.
16. Воронов, А. Г. Геоботаника / А. Г. Воронов. – М.: Высшая школа, 1973. – 384 с.
17. Галушкин, А. И. Нейронные сети: основы теории / А. И. Галушкин. – М.: Горячая линия-Телеком, 2010. – 480 с.
18. Горелик, А. Л. Методы распознавания / А. Л. Горелик, В. А. Скрипник. – М.: Высшая школа, 1989. – 232 с.
19. Дремин, И. М. Вейвлеты и их использование / И. М. Дремин, О. В. Иванов, В. А. Нечитайло // Успехи физических наук. – 2001. – №5 (171). – С. 465-501.
20. Дуда, Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт. – М.: Мир, 1976. – 509 с.
21. Епифанцев, Б. Н. Об одном алгоритме распознавания текстур на аэрофотоснимках / Б. Н. Епифанцев, В. А. Молодых // Изв. вузов. Геодезия и аэрофотосъемка. – 1978. – №2. – С. 84-89.
22. Живичин, А. Н. Дешифрирование фотографических изображений / А. Н. Живичин, В. С. Соколов. – М.: Недра, 1980 – 253 с.

23.Жири́н, В. М. Оценка возможностей дешифрирования лесообразующих пород по космическим снимкам IKONOS / В. М. Жири́н, С. В. Князева // Современные проблемы дистанционного зондирования Земли из космоса Сборник тезисов конференции. – 2008. – С. 373-379.

24.Журавлев, Ю. И. Алгоритмы распознавания, основанные на вычислении оценок / Ю. И. Журавлев, В. В. Никифоров // Кибернетика. – 1971. – №3. – С. 1-11.

25.Журбин, И. В. Комплексное применение низковысотной аэрофотосъемки и геофизических методов в археологических исследованиях / И. В. Журбин, В. Н. Милич, А. И. Назмутдинова, Р. П. Петров, Н. Г. Воробьева // Инженерная физика. – 2016. – №12. – С. 74-81.

26.Журкин, И. Г. Тексту́рный анализ фотоизображений в задачах дешифрирования и классификации природных объектов / И. Г. Журкин, В. В. Гаврилова // Обработка изображений и дистанционные исследования: Тез. докл. Всесоюз. конф. – 1984. – ч.3. – С. 47-48.

27.Зубков, И. А. Применение алгоритмов неконтролируемой классификации при обработке данных ДЗЗ / И. А. Зубков, В. О. Скрипачев // Современные проблемы дистанционного зондирования Земли из космоса. – 2007. – №4 (1). – С. 57-62.

28.Калабухов, А. А. ГИС и метод расчета вегетационных индексов NDVI для оценки экологического состояния растительного покрова нефтедобывающих территорий Каргасокского района Томской области / А. А. Калабухов // Современные проблемы географии и геологии. Материалы III Международной научно-практической конференции. – 2014. – С. 294-297.

29.Кашкин, В. Б. Дистанционное зондирование Земли из космоса. Цифровая обработка изображений: Учебное пособие / В. Б. Кашкин, А. И. Сухинин – М.: Логос, 2001. – 264 с.

30.Книжников, Ю. Ф. Аэрокосмические методы географических исследований / Ю. Ф. Книжников, В. И. Кравцова, О. В. Тутубалина – М.: Издательский центр «Академия», 2004. – 336 с.

31. Ковалевская, Н. М. Оценка площадей посевов по многоспектральным спутниковым данным SPOT-4 и LANDSAT ETM+ / Н. М. Ковалевская, Т. Г. Денисова // Известия высших учебных заведений. Геодезия и аэрофотосъемка. – 2013. – № 4. – С. 46-51.
32. Колодникова, Н. В. Обзор текстурных признаков для задач распознавания образов / Н. В. Колодникова // Доклады ТУСУРа. Автоматизированные системы обработки информации, управления и проектирования. – 2004. – С. 113-124.
33. Королук, В. С. Справочник по теории вероятностей и математической статистике / В. С. Королук, Н. И. Портенко, А. В. Скороход, А. Ф. Турбин – М.: Наука, 1985. – 640 с.
34. Короновский, А.А. Непрерывный вейвлетный анализ и его приложения / А. А. Короновский, А. Е. Храмов. – М.: Физматлит, 2003. – 176 с.
35. Коняев, К. В. Спектральный анализ случайных процессов и полей / К. В. Коняев. – М.: Наука, 1973. – 178с.
36. Космическая и радарная космосъемка Земли высокого и сверхвысокого разрешения. Совзонд [электронный ресурс]. URL: <http://www.sovzond.ru/products/spatial-data/satellites> (дата обращения: 02.10.2016).
37. Кудрявцев, В. Б. Теория тестового распознавания / В. Б. Кудрявцев, А. Е. Андреев, Э. Э. Гасанов. – М.: Физматлит, 2007. – 320 с.
38. Кучко, А. С. Аэрофотография / А. С. Кучко. – М.: Недра, 1974. – 272 с.
39. Лабутина, И. А. Дешифрирование аэрокосмических снимков: Учеб. пособие для студентов вузов / И. А. Лабутина. – М.: Аспект Пресс, 2004. – 184 с.
40. Лебедев, Д. С. Марковская вероятностная модель изображения и рисунка. Препринт. / Д. С. Лебедев, А. А. Безрук, В. М. Новиков. – М.: ИППИ АН СССР, 1983. – 40 с.
41. Лиджиева, Н. Ц. Опыт применения индекса вегетации (NDVI) для определения биологической продуктивности фитоценозов аридной зоны на примере региона Черные земли / Н. Ц. Лиджиева, С. С. Уланова, Н. Л. Федорова // Известия Саратовского университета. – 2012. – №2 (12). – С. 94-96.

42. Лурье, И. К. Геоинформационное картографирование. Методы геоинформатики и цифровой обработки космических снимков: учебник / И. К. Лурье. – М.: КДУ, 2008. – 424 с.

43. Маратканов, В. М. Принятие решений при интерпретации текстурных изображений / В. М. Маратканов, В. Н. Милич, А. И. Мурынов, С. Н. Русов // Анализ и интерпретация пространственно-распределенных структур: Сб. науч. трудов. Свердловск: УрО АН СССР. – 1988. – С. 36-49.

44. Милич, В. Н. К задаче выбора эффективных признаков текстурных изображений / В. Н. Милич // Дискретные системы обработки информации. – Ижевск. – 1982. – №4. – С. 71-78.

45. Мурынов, А. И. Анализ однородных пространственно-распределенных стохастических структур / А. И. Мурынов // Анализ и интерпретация пространственно-распределенных структур: Сб. науч. трудов. – 1988. – С. 5-21.

46. Назмутдинова, А.И. Исследование признаков, построенных на основе вейвлетов, при определении характеристик лесной растительности по результатам космической съемки / А. И. Назмутдинова, В. Н. Милич // Вестник Ижевского государственного технического университета. – 2015. – №1. – С. 94-95.

47. Назмутдинова, А. И. Исследование зависимости результатов классификации многозональных изображений лесной растительности от параметров вейвлет-преобразования / А. И. Назмутдинова, В. Н. Милич // Автометрия. – 2016. – №3 (52). – С. 20-27.

48. Назмутдинова, А.И. Исследование методов разделения классов в различных пространствах признаков при интерпретации материалов космической съемки / А. И. Назмутдинова, В. Н. Милич // Сборник тезисов докладов: X Всероссийская школа-конференция молодых ученых «КоМу-2013». – 2013. – С. 66-67.

49. Назмутдинова, А. И. Алгоритмическое и программное обеспечение вейвлет-анализа многозональных космических снимков / А. И. Назмутдинова, В. Н. Милич // X Всероссийская научно-практическая конференция «Инновации в

науке технике и технологиях» 28-30 апреля 2014: сборник статей. – 2014. – С. 189-191.

50. Назмутдинова, А. И. Использование вейвлет-преобразования при анализе многозональных изображений объектов лесной растительности / А. И. Назмутдинова, В. Н. Милич // Приборостроение в XXI веке – 2014. Интеграция науки, образования и производства: сб. материалов X Всерос. науч.-техн. конф. с междунар. участием (Ижевск, 12-14 нояб. 2014 г.). – 2015. – С.588-591.

51. Назмутдинова, А. И. Оценка влияния техногенных процессов на лесные территории с помощью метода, основанного на вейвлет-преобразовании многозональных изображений / А. И. Назмутдинова, В. Н. Милич // Материалы Всероссийской научно-практической конференции «Энергосбережение и инновационные технологии в топливно-энергетическом комплексе». – 2015. – С.171-174.

52. Назмутдинова, А. И. Исследование возможностей классификации многозональных изображений объектов лесной растительности с использованием вейвлет-признаков / А. И. Назмутдинова, В. Н. Милич // Информационные технологии в науке, промышленности и образовании: сб. тр. регион. науч.-техн. конф. (г. Ижевск, 23 мая 2015). – 2015. – С.99-104.

53. Назмутдинова, А. И. Возможности экологического мониторинга территорий в районе опасных промышленных объектов по многозональным космическим изображениям земной поверхности / А. И. Назмутдинова, В. Н. Милич // «Химическое разоружение-2015: итоги и аспекты технологических решений, экоаналитического контроля и медицинского мониторинга «СHEMDET-2015»: IV Всероссийская конференция, Ижевск, 14-18 сентября 2015 г.: сборник трудов. – 2015. – С. 90-94.

54. Назмутдинова, А. И. Метод интерпретации космических снимков площадных объектов местности на основе вейвлет-анализа / А. И. Назмутдинова, В. Н. Милич // Приборостроение в XXI веке – 2015. Интеграция науки, образования и производства: сб. материалов XI Междунар. науч.-техн. конф. (Ижевск, 25–27 нояб. 2015 г.). – 2016. – С.595-600.

55. Назмутдинова, А. И. Применение вейвлет-признаков при классификации объектов на многозональных космических снимках / А. И. Назмутдинова, В. Н. Милич // News of science: Proceedings of materials the international scientific conference. Czech Republic, Karlovy Vary - Russia, Moscow, 30-31 August 2015. – 2015. – P. 495-500.

56. Назмутдинова, А. И. Применение многозональной съемки с низколетящих аппаратов для обнаружения областей с характерными свойствами / А. И. Назмутдинова, В. Н. Милич // Информационные технологии в науке, промышленности и образовании: сб. тр. регион. науч.-техн. конф. (г. Ижевск, 21 мая 2016) / науч. ред. В.А. Куликов. – 2016. – С.185-192.

57. Напрюшкин, А. А. Алгоритмическое и программное обеспечение системы интерпретации аэрокосмических изображений для решения задач картирования ландшафтных объектов: дис. канд. тех. наук: 05.13.11 / Напрюшкин Александр Алексеевич. – Томск, 2002. – 183 с.

58. Обработка сигналов и изображений. «Вейвлеты, аппроксимация и статистические приложения» (перевод К. А. Алексеева) [электронный ресурс]. URL: <http://matlab.exponenta.ru/wavelet/book6/> (дата обращения: 02.10.2016).

59. Потапов, А. А. Новые информационные технологии на основе вероятностных текстурных и фрактальных признаков в радиолокационном обнаружении малоконтрастных целей / А. А. Потапов // Радиотехника и электроника. – 2003. – №9 (48). – С. 1101-1119.

60. Прохоров, Ю. В. Теория вероятностей / Ю. В. Прохоров, Ю. А. Розанов. – М.: Наука, 1973. – 496 с.

61. Прэтт, У. Цифровая обработка изображений. Пер. с англ. / У. Прэтт. – М.: Мир, 1982. – 312 с.

62. Пытьев, Ю. П. Задача улучшения качества изображений / Ю. П. Пытьев // Доклады Академии наук. – 1979. – Т. 245. – С. 315-319.

63. Романенко, А. Ф. Вопросы прикладного анализа случайных процессов / А. Ф. Романенко, Г. А. Сергеев. – М.: Сов. Радио, 1986. – С.71-81.

64. Романов, А. А. Эффективность непараметрических классификаторов в условиях лимитированной обучающей выборки / А. А. Романов, К. А. Рубанов // Journal of Siberian Federal University. Engineering & Technologies. – 2012. – №5. – С. 495-506.

65. Савиных, В. П. Геоинформационный анализ данных дистанционного зондирования / В. П. Савиных, В. Я. Цветков – М.: Картгеоцентр – Геодезиздат. – 2001. – 228 с.

66. Свидетельство о государственной регистрации программы для ЭВМ № 2016613178 от 18.03.2016. / Программное обеспечение определения разновидностей объектов растительности по их многозональным изображениям // А.И. Назмутдинова, В.Н. Милич; Оpubл. – 20.04.2016.

67. Сергеев, Г. А. Статистические методы исследования природных объектов / Г. А. Сергеев, Д. А. Янутш. – Л.: Гидрометеиздат, 1973. – 300 с.

68. Смоленцев, Н. К. Основы теории вейвлетов. Вейвлеты в Matlab / Н. К. Смоленцев. – М.: ДМК Пресс. – 304 с.

69. Сурин, В. Г. Возможности использования гиперспектрометра «Лептон» для мониторинга состояния почвенно-растительного комплекса / В. Г. Сурин, К. Г. Моисеев, А. Е. Курашвили // Агрофизика. – 2012. – №4(8). – С. 34-44.

70. Терехин, Э. А. Информативность спектральных вегетационных индексов для дешифрирования сельскохозяйственной растительности / Э. А. Терехин // Современные проблемы ДЗЗ из космоса. – 2012. – №4(9). – С. 243-248.

71. Токарева, О. С. Обработка и интерпретация данных дистанционного зондирования Земли. Учебное пособие / О. С. Токарева. – Томск: Изд-во Томского политехнического университета, 2010. – 148 с.

72. Фраленко, В. П. Методы текстурного анализа изображений, обработка данных дистанционного зондирования Земли / В. П. Фраленко // Программные системы: теория и приложения. – 2014. – №4(22). – С. 19-39.

73. Харалик, Р. М. Статистический и структурный подходы к описанию текстур / Р. М. Харалик // ТИИЭР. – 1979. – №5(67). – С. 98-120.

74. Хомяков, Ю. Н. Методы классификации текстур / Ю. Н. Хомяков, В. А. Саушкин // Зарубежная радиоэлектроника. – 1986. – №2. – С. 33-46.
75. Чандра, А. М. Дистанционное зондирование и географические информационные системы / А. М. Чандра, С. К. Гош. – М.: Техносфера, 2008. – 312 с.
76. Черепанов, А. С. Вегетационные индексы. Справочный раздел / А. С. Черепанов // Геоматика. – 2011. – №2. – С. 98 – 102.
77. Шелестов, А. Оценка биоразнообразия с использованием нейронных сетей / А. Шелестов, Е. Насуро, С. Скакун // Proceedings of International Conference «Knowledge-Dialogue-Solutions». – 2007. – С. 49-54.
78. Шовенгердт, Р. А. Дистанционное зондирование. Методы и модели обработки изображений / Р. А. Шовенгердт. – М.: Техносфера, 2010. – 560 с.
79. Шумаков, Ф. Т. Классификация космических снимков с использованием методов кластерного анализа / В. А. Толстохатко, А. Ю. Малец // Восточно-Европейский журнал передовых технологий. – 2011. – № 4(51). – С. 58-62.
80. Ярославский, Л. П. Цифровая обработка сигналов в оптике и голографии: Введение в цифровую оптику / Л. П. Ярославский. – М.: Радио и связь, 1987. – 296 с.
81. Agrawal, R. PSO based Selection of Spectral Features for Remotely Sensed Image Classification / R. Agrawal, N. Bawane // Proceeding of International Conference on Advances in Computer Science. – 2013. – P. 143-149.
82. Ahmad, A. Analysis of Maximum Likelihood Classification on Multispectral Data / A. Ahmad, S. Quegan // Applied Mathematical Sciences, V. 6. – 2012. – № 129. – P. 6425-6436.
83. Ahmad, A. Comparative Analysis of Supervised and Unsupervised Classification on Multispectral Data / A. Ahmad, S. Quegan // Applied Mathematical Sciences, V. 7. – 2013. – № 74. – P. 3681-3694.
84. Akar, O. Classification of multispectral images using Random Forest algorithm / O. Akar, O. Gungor // Journal of Geodesy and Geoinformation. – 2012. – №2 (1). – P. 105-112.

85. Al-Ahmadi, F. S. Comparison of Four Classification Methods to Extract Land Use and Land Cover from Raw Satellite Images for Some Remote Arid Areas, Kingdom of Saudi Arabia / F. S. Al-Ahmadi, A. S. Hames // Journal of King Abdulaziz University: Earth Sciences. – 2009. – №1(20). – P. 167-191.

86. Anderson, J. R. A Land Use and Land Cover Classification System for Use with Remote Sensor Data / E. E. Hardy, J. T. Roach, R.E. Witner. – US Government Printing Office, 1976. – 28 p.

87. Balasubramanian, R. Wavelet Application in compression of a Remote Sensed Image / R. Balasubramanian, S. S. Ramakrishan // International Conference on Remote Sensing, Environment and Transportation Engineering. – 2013. – P. 661-664.

88. Bekkari, A. SVM Classification of Urban High Resolution Imagery using Composite Kernels and Contour Information / A. Bekkari, M. El Yassa, S. Idbraim, D. Mammass, A. Elhassouny, D. Ducrot // International Journal of Advanced Computer Science and Applications. – 2013. – №7(4). – P. 126-141.

89. Bekkari, A. SVM Classification of High Resolution Urban Satellites Images using Haralick Features / A. Bekkari, S. Idbraim, A. Elhassouny, D. Mammass, M. E. Yassa, D. Ducrot // International Journal of Scientific & Engineering Research. – 2012. – №6(3). – P. 1-7.

90. Bekkari, A. SVM Classification of High Resolution Urban Satellites Images using Composite Kernels and Haralick Features / A. Bekkari, S. Idbraim, D. Mammass, M. E. Yassa // Journal of Emerging Technologies in Web Intelligence. – 2014. – №1(6). – P. 69-74.

91. Breiman, L. Random Forests / L. Breiman // Machine Learning. – 2001. – №1(45). – P. 5-32.

92. Chen, C. H. A Study of Texture Classification Using Spectral Features / C. H. Chen // Proc. 6th Intern. Conf. on Pattern Recognition, Munich, Oct. 19-22, 1982. – P. 1074-1077.

93. Chen, J. Wavelet-Based Classification of Remotely Sensed Images: A Comparative Study of Different Feature Sets in an Urban Environment / J. Chen, D. Chen, D. Blostein // Journal of Environmental Informatics. – 2007. – №10(1). – P. 2-9.

94. Choudhary D. Performance Analysis of Texture Image Classification Using Wavelet Feature / D. Choudhary, A. K. Singh, S. Tiwari, V. P. Shukla // I.J. Image, Graphics and Signal Processing. – 2013. – №1. – P. 58-63.
95. Congalton, R. G. Assessing the Accuracy of Remotely Sensed Data. Principles and Practices. Second Edition / R. G. Congalton, K. Green. – Boca Raton: Taylor & Francis Group, 2009. – 183 p.
96. Cohen, J. A coefficient of agreement for nominal scales / J. Cohen // Educational and Psychological Measurement. – 1960. – № 20 (1). – P. 37-46.
97. Cross, R. Markov Random Field Texture Models / R. Cross, K. Jain // IEEE Trans. – 1983. – №1. – P. 25-39.
98. Da Silva, R. D. Image segmentation based on wavelet feature descriptor and dimensionality reduction applied to remote sensing / R. D. Da Silva, W. R. Schwartz, H. Pedrini // Chilean Journal of Statistics. – 2011. – №2(2). – P. 51-60.
99. Dyer, C. Fourier Texture Features: Suppression of Aperture Effects / C. Dyer, A. Rosenfeld // IEEE Trans. – 1976. – №10. – P. 703-705.
100. Fdez-Sarria, A. Study of methods based on wavelets for texture classification of high resolution images / A. Fdez-Sarria, L. A. Ruiz, J. A. Recio // 25th EARSeL Symposium. Global Developments in Environmental Earth Observation from Space, 2005. – P. 19-27.
101. Foody, G. M. Status of land cover classification accuracy assessment / G. M. Foody // Remote Sensing of Environment. – 2002. – №80. – P. 185-201.
102. Foody, G. M. Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification / G. M. Foody, A. Mathur // Remote Sensing of Environment. – 2004. – №1 (93). – P. 107-117.
103. Forests and the forestry sector. Russian Federation [Electronic resource] / Food and Agriculture Organization of the United Nations, 2016. – URL: <http://www.fao.org/forestry/country/57478/en/rus/> (Date of access: 13.12.2016).
104. Georgescu, F.-A. Gabor and Wavelet local descriptors performance in multispectral earth observation image data analysis / F.-A. Georgescu, M. Datcu, D.

Raducanu // Scientific Research & Education in the Air Force – AFASES. – 2015. – №2. – P. 331-335.

105. Ghimire, B. Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic / B. Ghimire, J. Rogan, J. Miller // Remote Sensing Letters. – 2010. – №1. P. 45-54.

106. Gonzalez-Audicana, M. Comparison between Mallat's and the 'à trous' discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images / M. Gonzalez-Audicana, X. Otazu, O. Fors, A. Seco // International Journal of Remote Sensing. – 2005. – P. 1-15.

107. Haralick, R. M. Textural Features for Image Classification / R. M. Haralick, K. Shanmugam, I. Dinstein // IEEE Transactions on Systems, Man and Cybernetics. – 1979. – №3. – P. 610-621.

108. Harikrishnan, R. Satellite Image Classification for IRS Data Based on Supervised and Unsupervised Algorithms Using ERDAS / R. Harikrishnan, S. Poongodi // International Conference on Engineering Trends and Science & Humanities, 2015. – P. 112-116.

109. Hassner, M. The Use of Markov Random Fields as Models of Texture / M. Hassner, J. Sklansky // Comp. Graph. and Image Proc. – 1980. – №4. – P. 357-370.

110. Holschneider, M. A real-time algorithm for signal analysis with the help of the wavelet transform / M. Holschneider, R. Kronland-Martinet, J. Morlet, P. Tchamitchian // In Wavelets, Time-Frequency Methods and Phase Space, 1989. – P. 289-297.

111. Hughes, G. F. On the mean accuracy of statistical pattern recognizers / G. F. Hughes // IEEE Transactions on Information Theory. – 1968. – №1(14). – P. 55-63.

112. Hui, S. Discrete Fourier transform based pattern classifiers / S. Hui, S. H. Zak // Bulletin of the Polish Academy of Sciences: Technical Sciences. – 2014. – №1(62). – P. 15-22.

113. Hsu, P. H. Classification of Hyperspectral Images Using Wavelet Networks / P. H. Hsu // Proceedings of the American Society of Photogrammetry and Remote Sensing (ASPRS) 2006 Annual Conference, Reno, 2006. – P. 1-5.
114. Hsu, P.-H. Spectral Feature Extraction of Hyperspectral Images Using Wavelet Transform / P.-H. Hsu, Y.-H. Tseng, P. Cong // Journal of Photogrammetry and Remote Sensing. – 2006. – №1(11). – P. 93-109.
115. Hsu, S. The Mahalonobis Classifier with the Generalized Inverse Approach for Automated Analysis of Imagery Texture Data / S. Hsu // Comp. Graph. and Image Proc. – 1979. – №4. – P.117-134.
116. Idelsohn, J. M. A Learning System for Terrain Recognition / J. M. Idelsohn // Pattern Recogn. – 1970. – №4. – P. 293-302.
117. Immitzer, M. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data / M. Immitzer, C. Atzberger, T. Koukal // Remote Sensing. – 2012. – №4. – P. 2661-2692.
118. Kharat, S. A. Cotton Crop Discrimination Using Landsat-8 Data / S. A. Kharat, V. B. Musande // International Journal of Computer Science and Information Technologies. – 2015. – №5 (6). – P. 4381-4384.
119. Kosaka, N. Forest Type Classification Using Data Fusion of Multispectral and Panchromatic High-Resolution Satellite Imageries / N. Kosaka, T. Akiyama, B. Tsai, T. Kojima // Proceedings of the 2005 Geoscience and Remote Sensing Symposium, 2005. – P. 25-29.
120. Kumar, M. A Neural-Wavelet Based Image Classification for Feature Extraction of a Multispectral Remote Sensing Data / M. Kumar, J. Singh // International Journal of Advanced Research in Computer and Communication Engineering. – 2013. – №7(2). – P. 2785-2791.
121. Kavzoglu, T. A kernel functions analysis for support vector machines for land cover classification / T. Kavzoglu, I. Colkesen // International Journal of Applied Earth Observation and Geoinformation. – 2009. – № 5 (11). – P. 352-359.
122. Lawrence, R. Classification of remotely sensed imagery using stochastic gradient boosting as a refinement of classification tree analysis / R. Lawrence, A. Bunn,

S. Powell, M. Zambon // Remote Sensing of Environment. – 2004. – №90. – P. 331-336.

123. Lowe, B. Multispectral Image Analysis Using Random Forest / B. Lowe, A. Kulkarni // International Journal on Soft Computing (IJSC). – 2015. – №1(6). – P. 1-14.

124. Mallat, S. A wavelet tour of signal processing / S. Mallat. – Academic press, 1999. - 637 p.

125. Measuring Vegetation (NDVI & EVI). Normalized Difference Vegetation Index (NDVI) [Electronic resource]. URL: http://earthobservatory.nasa.gov/Features/MeasuringVegetation/measuring_vegetation_2.php (Date of access: 13.11.2016).

126. Meher, S. K. Wavelet-Feature-Based Classifiers for Multispectral Remote-Sensing Images / S. K. Meher, B. Uma Shankar, A. Ghosh // IEEE Transactions on Geoscience and Remote Sensing. – 2007. – №6. – P. 1881-1886.

127. Minu Nair, S. Supervised Techniques and Approaches for Satellite Image Classification / S. Minu Nair, J. S. Bindhu // International Journal of Computer Applications. – 2016. – №16 (134). P. 1-6.

128. Mountrakis, G. Support vector machines in remote sensing: A review / G. Mountrakis, J. Im, C. Ogole // ISPRS Journal of Photogrammetry and Remote Sensing. – 2011. – №3 (66). – P. 247-259.

129. Ozdarici-Ok, A. Mapping of Agricultural Crops from Single High-Resolution Multispectral Images – Data-Driven Smoothing vs. Parcel-Based Smoothing / A. Ozdarici-Ok, A. O. Ok, K. Schindler // Remote Sensing. – 2015. – № 7. –P. 5611-5638.

130. Padma, S. Jeffries Matusita – Spectral Angle Mapper (JM-SAM) Spectral Matching for Species Level Mapping at Bhitarkanika, Muthupet and Pichavaram Mangroves / S. Padma, S. Sanjeevi // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. – 2014. – P. 1403-1411.

131. Pearson, K. On lines and planes of closest fit to systems of points in space / K. Pearson // The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science. – 1901. – №11 – P. 559-572.
132. Perumal, K. Supervised Classification Performance of Multispectral Images / K. Perumal, R. Bhaskaran // Journal of Computing. – 2010. – №2 (2). – P. 124-129.
133. Plaza, A. Recent advances in techniques for hyperspectral images / A. Plaza, J.A. Benediktsson, J. W. Boardman, J. Brazile, L. Bruzzone et. al. // Remote Sensing of Environment. – 2009. – №10 (113). – P. 110-122.
134. Ruiz, L. A. Texture feature extraction for classification of remote sensing data using wavelet decomposition: a comparative study / L. A. Ruiz, A. Fdez-Sarría, J. A. Recio // 20th ISPRS Congress. – 2004. – № 35 (B). – P. 1109-1114.
135. Saritha, S. A Hierarchical Framework for the Classification on Multispectral Imagery / S. Saritha, G. S. Kumar // Procedia Computer Science. – 2015. – №25. – P. 78-85.
136. Shafri Helmi, Z. M. Wavelet Shrinkage in Noise Removal of Hyperspectral Remote Sensing Data / Z. M. Shafri Helmi, P. M. Mather // American Journal of Applied Sciences. – 2005. – №2(7). – P. 1169-1173.
137. Smits, P. C. Quality assessment of image classification algorithms for land-cover mapping: a review and proposal for a cost-based approach / P. C. Smits, S. G. Dellepiane, R. A. Showengerdt // International Journal of Remote Sensing. – 1999. – №8 (20). – P. 1461-1486.
138. Szuster, B. W. A Comparison of classification techniques to support land cover and land use analysis in tropical coastal zones / B. W. Szuster, Q. Chen, M. Borger // Applied Geography. – 2011. – № 31. – P. 525-532.
139. Thakare, V. S. Survey on Image Texture Classification Techniques / V. S. Thakare, N. N. Patil, J. S. Sonawane // International Journal of Advancements in Technology. – 2013. – №1 (4). – P. 97-104.

140. White Paper. The RapidEye Red Edge Band [Electronic Resource] / RESA - RapidEye Science Archive. – URL: https://resa.blackbridge.com/files/2014-06/Red_Edge_White_Paper.pdf (Date of access: 03.12.2016).

141. Yu, Q. Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery / Q. Yu, P. Gong, N. Clinton, G. Biging, M. Kelly, D. Schirokauer // Photogrammetric Engineering & Remote Sensing. – 2006. – №7(72). – P. 799-811.

142. Yuan, F. Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing / F. Yuan, K. E. Sawaya, B. C. Loeffelholz, M. E. Bauer // Remote Sensing of Environment. – 2005. – №98. – P. 317-328.

143. Zhang, L. On Combining Multiple Features for Hyperspectral Remote Sensing Image Classification / L. Zhang, D. Tao, X. Huang // IEEE Transactions on Geoscience and Remote Sensing. – 2012. – №3 (50). – P. 879-89

Приложение А
(справочное)

Таблица А.1 – Характеристики известных реализаций систем интерпретации изображений площадных объектов местности (ОС - однородность по составу исследуемых объектов, НС - наличие разрешимой структуры)

№ п/п, год, ссылка	Признаки	Метод классификации	Резуль- таты	Классы объектов	Разреше- ние снимка	ОС	НС
1 2004, [122]	Спектральные признаки	Дерево принятия решений	95 %	4 класса: деревья; вода; луга; камни (утёсы).	4 канала, 4 м	+	+
2 2004, [122]	Спектральные признаки	Дерево принятия решений	93%	6 классов: вода; хвойные леса; лиственные леса; развитые районы; пастбища; поврежденная земля.	128 каналов, 5 м	+	+
3 2004, [122]	Спектральные признаки	Дерево принятия решений	62 %	6 классов: хвойные леса; хвойные/травянистые; сгоревшие области; хвойные/лиственные леса; лиственные леса; травяной покров.	6 каналов, 30 м	+	-
4 2005, [142]	Спектральные признаки	Метод управляемой кластеризации	94 %	7 классов: с/х культуры; трава; песчано- гравийные карьеры; леса; город; вода; пастбища.	7 каналов, 30 м	+	-

Продолжение таблицы А.1

№ п/п, Год, ссылка	Признаки	Метод классификации	Резуль- таты	Классы объектов	Разреше- ние снимка	ОС	НС
5 2007, [77]	Спектральные признаки	Нейронные сети	89 %	8 классов: лиственный лес; хвойный лес; смешанный лес; пашня; пастбище; вода; искусственные материалы; открытая местность.	6 каналов, 30 м	+ -	-
6 2010, [131]	Спектральные признаки	Расстояние Махаланобиса	99 %	3 класса: почва; растительность; реки.	4 канала, 23,5 м	+	-
7 2012, [84]	Спектральные признаки	Случайный лес	83 %	8 классов: лес-1; лес-2; фруктовый сад; трава; почва; дороги; городская структура; тени.	4 канала, 2.4 м	+ -	+ -
8 2012, [82]	Спектральные признаки	Метод максимального правдоподобия	97 %	11 классов: леса, прибрежные к болотам; леса засушливых районов; пальмы; каучук; убранные земли; засыпные шлейфы; вода; кокос; пустоши; городские застройки; промышленность.	7 каналов, 30 м	+	- +
9 2012, [70]	Спектральные признаки	Метод максимального правдоподобия	57 %	5 классов: ячмень яровой, пшеница озимая; подсолнечник; многолетние травы; кукуруза.	7 каналов, 30 м.	+	-
10 2015, [123]	Спектральные признаки	Случайного леса	96 %	4 класса: вода; почва; леса; с/х культуры.	9 каналов, 30 м	+	-

Продолжение таблицы А.1

№ п/п, Год, ссылка	Признаки	Метод классификации	Результаты	Классы объектов	Разрешение снимка	ОС	НС
11 2015, [135]	Спектральные признаки	Итеративная иерархическая модель классификации	73 %	4 класса: застроенные земли; с/х культуры; леса; пустоши.	0.3 м	+ -	+
12 2015, [135]	Спектральные признаки	Итеративная иерархическая модель классификации	78 %	13 классов: жилые районы; коммерческие районы; промышленные; транспорт; смешанные городские земли; пахотные земли; садовые; лиственные леса; хвойные леса; смешанные леса; песчаные земли; скалы; детские площадки.	0.3 м	+ -	+
13 2015, [129]	Спектральные признаки	Метод опорных векторов	93 %	6 классов: кукуруза; пастбище; рис; сахарная свекла; пшеница; помидоры.	4 канала, 4м	+	-
14 2015, [118]	Спектральные признаки	Кластеризация K- means	96 %	4 класса: водные объекты; хлопок; жилые районы; сухая растительность.	11 каналов, 15- 100 м	+	-
15 2015, [104]	Текстурные признаки (Габор)	Метод опорных векторов	от 48 % до 88 %	5 классов: городские застройки-1 (цветные); городские застройки-2 (серые); плотная растительность; растительность низкой плотности; вода.	8 каналов, 2 м	+ -	+

Продолжение таблицы А.1

№ п/п, Год, ссылка	Признаки	Метод классификации	Резуль- таты	Классы объектов	Разреше- ние снимка	ОС	НС
16 2004, [134]	Спектральные признаки Текстурные признаки	Метод максимального правдоподобия	83 %	9 классов: густой лес; лес-кустарник; густой кустарник; разрозненные деревья; травянистая растительность или сорняки; зерновые или пастбища; неспаханые земли; жилые районы; море.	4 канала, 2.4 м	-	+
17 2005, [119]	Спектральные признаки Признаки Харалика	Метод ближайшего соседа	73 %	6 классов: кедр; кипарис; лиственница; смешанные леса (хвойные); смешанные леса (широколиственные деревья); широколиственные леса.	4 канала, 2.4 м (0.6 м)	+ -	+
18 2006, [141]	Спектральные признаки Текстурные признаки	Метод ближайшего соседа и максимального правдоподобия	57 %	4 класса: леса; кустарники; трава; другое.	4 канала, 1 м	+	+ -
19 2006, [141]	Спектральные признаки Текстурные признаки	Классификатор ближайшего соседа и метод максимального	44 %	48 классов	4 канала, 1 м	-	+

Продолжение таблицы А.1

№ п/п, Год, ссылка	Признаки	Метод классификации	Резуль- таты	Классы объектов	Разреше- ние снимка	ОС	НС
20 2010, [105]	Спектральные признаки Текстурные признаки	Случайный лес	93 %	8 классов: клюквенные болота; пропашные культуры; леса; луга; городские застройки; вода; водно-болотные угодья; песчаный карьер.	7 каналов, 30 м	+	-
21 2013, [88]	Спектральные и признаки Харалика	Метод опорных векторов	93 %	6 классов: асфальт; трава; деревья; почва; постройки; тени.	4 канала, 3.3 м	+	- +
22 2004, [134]	Текстурные и вейвлет- признаки	Метод максимального правдоподобия	76 %	7 классов: леса высокой плотности; леса средней плотности; лес с кустарниками; кусты; разрозненные деревья; разрозненные кусты; оливковые деревья.	1 канал, 1 м	-	+
23 2004, [134]	Текстурные и вейвлет- признаки	Метод максимального правдоподобия	82 %	9 классов: леса высокой плотности; леса средней плотности; леса низкой плотности; кустарники высокой плотности; кустарники низкой плотности; злаки; миндальные деревья; площади лесовосстановления; с/х культуры.	1 канал, 1 м	-	+

Продолжение таблицы А.1

№ п/п, Год, ссылка	Признаки	Метод классификации	Результаты	Классы объектов	Разрешение снимка	ОС	НС
24 2004, [134]	Текстурные признаки Вейвлет- признаки	Метод максимального правдоподобия	88 %	6 классов: старые городские районы; новые городские районы; дисперсные жилые районы за пределами города; промышленные районы; сады; цитрусовые сады.	1 канал, 5 м	-	+
25 2005, [100]	Вейвлет- признаки	Метод максимального правдоподобия	88 %	6 классов: старые городские районы; новые городские районы; дисперсные жилые районы за пределами города; промышленные районы; сады; цитрусовые фруктовые сады.	1 канал, 1 м	-	+
26 2005, [100]	Вейвлет- признаки	Метод максимального правдоподобия	81 %	9 классов: густой лес; лес-кустарник; густой кустарник; разбросанные деревья; травянистая растительность или сорняки; зерновые или пастбища; неспаханые земли; жилые районы; море.	1 канал, 1 м	-	+
27 2006, [113]	Вейвлет- признаки	Нейронные сети	86 %	4 класса: кукуруза; трава; соя-1; соя-2.	224 канала, 20 м	+	-
28 2007, [93]	Спектральные признаки Вейвлет- признаки	Метод минимального расстояния	89 %	10 классов: дороги/транспорт; жилые районы; коммерческие районы; хвойные леса; с/х культуры; орошаемые земли; водно-болотные земли; пустоши; водные объекты; лиственные леса.	4 канала, 4 м	+	- +

Приложение Б

(Справочное)

Текст программы «Программное обеспечение определения разновидностей объектов растительности по их многозональным изображениям»

```

# основная программа
import opticks
import numpy as np
from numpy import *

# ввод исходной информации
# загрузить многозональное изображение
l=opticks.RasterLayer()
re=l.element
r=re.data_array[...]
qband=r.shape[2] # записываем в qband количество спектральных зон снимка
# ввести координаты x1,x2,y1,y2 используемых образцов
bao1=np.array([1842, 1535, 1860, 1553], dtype="float32")
bao2=np.array([1848, 1488, 1866, 1506], dtype="float32")
bao3=np.array([1842, 1509, 1860, 1527], dtype="float32")
bao4=np.array([1564, 1751, 1581, 1768], dtype="float32")
bao5=np.array([1427, 2001, 1445, 2020], dtype="float32")
bao6=np.array([1407, 2024, 1425, 2045], dtype="float32")
bao7=np.array([1867, 1625, 1900, 1658], dtype="float32")
# сформировать массивы пикселей изображения, соответствующих введенным ранее координатам
aoi1=for_bao(bao1,r)
aoi2=for_bao(bao2,r)
aoi3=for_bao(bao3,r)
aoi4=for_bao(bao4,r)
aoi5=for_bao(bao5,r)
aoi6=for_bao(bao6,r)
aoi7=for_bao(bao7,r)
#Обучение метода классификации
#формируем массив, состоящий из векторов обучающих образцов. В данном случае, 2 класса, 3
#обучающих образца для каждого класса, 40*qband – длина вектора признаков,SHAN- набор коэф-в,
#соот-х н.ч.ф. вейвлета Шеннона-Котельникова
general_mas_aoi=np.zeros((2,3,40*qband), dtype="float")
general_mas_aoi[0,0,:]= AOI1(aoi1,qband,SHAN)
general_mas_aoi[0,1,:]= AOI1(aoi2, qband,SHAN)
general_mas_aoi[0,2,:]= AOI1(aoi3, qband,SHAN)
general_mas_aoi[1,0,:]= AOI1(aoi4, qband,SHAN)
general_mas_aoi[1,1,:]= AOI1(aoi5, qband,SHAN)
general_mas_aoi[1,2,:]= AOI1(aoi6, qband,SHAN)
diapasons=forming_diapasons(general_mas_aoi,amount_zones) # amount_zones-кол-во сегментов, на
#которое будут разбиты диапазоны принимаемых значений признаков
mas_l=forming_massive_l(general_mas_aoi,diapasons)
reliability=calculation_reliability(general_mas_aoi,diapasons,mas_l)
significance=significance(general_mas_aoi,diapasons,mas_l)

# формирование вектора признаков для исследуемого образца

```

```
aoi7_test=AOI1(aoi7,qband, SHAN)
```

```
#Классификация исследуемого образца
```

```
classification(aoi7_test,diapasons,reliability,mas_1,significance)
```

```
def for_bao(mas_bao,r):
```

```
    mas_aoi=r[mas_bao[1]:mas_bao[3],mas_bao[0]:mas_bao[2],:]
    return mas_aoi
```

```
def AOI1(aoi,qband,wav): # формирование вектора признаков
```

```
    pr=np.zeros(40*qband, dtype="float32")
```

```
    norm_vh=0
```

```
    norm_dd1=0
```

```
    m=razmer(aoi)
```

```
    rr_wav=np.zeros((qband,m,m),dtype="float32")
```

```
    aoi_4=np.zeros((qband,m,m),dtype="float32")
```

```
    on_bands(aoi,aoi_4,m)
```

```
    i=0
```

```
    for j in range(qband):
```

```
        rr_wav[j]=dwt2(aoi_4[j],wav)
```

```
        #pr[j]=max_std(rr_wav[j])
```

```
    for j in range (qband):
```

```
        pr[j+i]=rr_wav[j,0:(m/2),0:(m/2)].mean() # аппр.ср.
```

```
        pr[j+i+1]=rr_wav[j,0:(m/2),(m/2):m].mean() # гориз.ср.
```

```
        pr[j+i+2]=rr_wav[j,(m/2):m,0:(m/2)].mean() # верт.ср.
```

```
        pr[j+i+3]=rr_wav[j,(m/2):m,(m/2):m].mean() # диаг.ср.
```

```
        pr[j+i+4]=rr_wav[j,0:(m/2),0:(m/2)].std() # аппр.откл.
```

```
        pr[j+i+5]=rr_wav[j,0:(m/2),(m/2):m].std() # гориз.откл.
```

```
        pr[j+i+6]=rr_wav[j,(m/2):m,0:(m/2)].std() # верт.откл.
```

```
        pr[j+i+7]=rr_wav[j,(m/2):m,(m/2):m].std() # диаг.откл.
```

```
        i=i+7
```

```
    rr_wav_ap,rr_wav_h,rr_wav_v,rr_wav_d=razbnadetaili(rr_wav)
```

```
    norm=(m*m)/4*1.0
```

```
    rr_wava_pr=preobr(rr_wav_ap,0.75)
```

```
    rr_wavh_pr=preobr(rr_wav_h,0.75)
```

```
    rr_wavv_pr=preobr(rr_wav_v,0.75)
```

```
    rr_wavd_pr=preobr(rr_wav_d,0.75)
```

```
    for j in range(qband):
```

```
        pr[j+i]=rr_wava_pr[j].sum()/norm
```

```
        pr[j+i+1]=rr_wavh_pr[j].sum()/norm
```

```
        pr[j+i+2]=rr_wavv_pr[j].sum()/norm
```

```
        pr[j+i+3]=rr_wavd_pr[j].sum()/norm
```

```
        i=i+3
```

```
    rr_wava_pr=preobr(rr_wav_ap,1.25)
```

```
    rr_wavh_pr=preobr(rr_wav_h,1.25)
```

```
    rr_wavv_pr=preobr(rr_wav_v,1.25)
```

```
    rr_wavd_pr=preobr(rr_wav_d,1.25)
```

```
    for j in range(qband):
```

```
        pr[j+i]=rr_wava_pr[j].sum()/norm
```

```
        pr[j+i+1]=rr_wavh_pr[j].sum()/norm
```

```
        pr[j+i+2]=rr_wavv_pr[j].sum()/norm
```

```
        pr[j+i+3]=rr_wavd_pr[j].sum()/norm
```

```
        i=i+3
```

```
    rr_wava_pr=preobr(rr_wav_ap,1)
```

```
    rr_wavh_pr=preobr(rr_wav_h,1)
```

```
    rr_wavv_pr=preobr(rr_wav_v,1)
```

```
    rr_wavd_pr=preobr(rr_wav_d,1)
```

```

for j in range(qband):
    pr[j+i]=rr_wava_pr[j].sum()/norm
    pr[j+i+1]=rr_wavh_pr[j].sum()/norm
    pr[j+i+2]=rr_wavv_pr[j].sum()/norm
    pr[j+i+3]=rr_wavd_pr[j].sum()/norm
    i=i+3
for j in range(qband):
    pik_a,means_a,max_a=kol_pik(rr_wava_pr[j])
    pik_h,means_h,max_h=kol_pik(rr_wavh_pr[j])
    pik_v,means_v,max_v=kol_pik(rr_wavv_pr[j])
    pik_d,means_d,max_d=kol_pik(rr_wavd_pr[j])
    pr[j+i]=pik_a
    pr[j+i+1]=means_a
    pr[j+i+2]=max_a
    pr[j+i+3]=pik_h
    pr[j+i+4]=means_h
    pr[j+i+5]=max_h
    pr[j+i+6]=pik_v
    pr[j+i+7]=means_v
    pr[j+i+8]=max_v
    pr[j+i+9]=pik_d
    pr[j+i+10]=means_d
    pr[j+i+11]=max_d
    i=i+11
rr_wava_pr=preobr01(rr_wav_ap,0.25)
rr_wavh_pr=preobr01(rr_wav_h,0.25)
rr_wavv_pr=preobr01(rr_wav_v,0.25)
rr_wavd_pr=preobr01(rr_wav_d,0.25)
for j in range(qband):
    pr[j+i]=rr_wava_pr[j].sum()/norm
    pr[j+i+1]=rr_wavh_pr[j].sum()/norm
    pr[j+i+2]=rr_wavv_pr[j].sum()/norm
    pr[j+i+3]=rr_wavd_pr[j].sum()/norm
    i=i+3
rr_wava_pr=preobr01(rr_wav_ap,0)
rr_wavh_pr=preobr01(rr_wav_h,0)
rr_wavv_pr=preobr01(rr_wav_v,0)
rr_wavd_pr=preobr01(rr_wav_d,0)
for j in range(qband):
    pr[j+i]=rr_wava_pr[j].sum()/norm
    pr[j+i+1]=rr_wavh_pr[j].sum()/norm
    pr[j+i+2]=rr_wavv_pr[j].sum()/norm
    pr[j+i+3]=rr_wavd_pr[j].sum()/norm
    i=i+3
return pr

```

```

def classification(attributes_sample,diapasons,reliability,l,significance):
    amount_attributes=attributes_sample.shape[0]
    amount_zones=diapasons.shape[1]
    amount_classes=reliability.shape[2]
    classes1=np.zeros(amount_classes, dtype="float")
    result=np.zeros(amount_classes, dtype="float")
    dop_attrib=np.zeros(amount_classes, dtype="float")
    for i in range(amount_attributes):
        j=0
        ind=0
        ind1=0

```

```

while (j<amount_zones-1):
    if (attributes_sample[i]>=diapasons[i,j])&(attributes_sample[i]<=diapasons[i,j+1]):
        ind=1
        for k in range(amount_classes):
            if (l[i,k,j]==1):
                classes1[k]=classes1[k]+1
                ind1=1
                dop_attrib[k]=dop_attrib[k]+reliability[i,j,k]*significance[i]
        if (ind1==0):
            if (j==0):
                for k in range(amount_classes):
                    if (l[i,k,j+1]==1):
                        classes1[k]=classes1[k]+1
                        ind1=1
                dop_attrib[k]=dop_attrib[k]+reliability[i,j+1,k]*significance[i]
            if (j==amount_zones-2):
                for k in range(amount_classes):
                    if (l[i,k,j-1]==1):
                        classes1[k]=classes1[k]+1
                        ind1=1
                        dop_attrib[k]=dop_attrib[k]+reliability[i,j-
1,k]*significance[i]
            else:
                distance=np.zeros(2, dtype="float32")
                distance[0]=abs(attributes_sample[i]-diapasons[i,j])
                distance[1]=abs(attributes_sample[i]-diapasons[i,j+1])
                r=j
                if (distance[0]>distance[1]):
                    r=j+1
                for k in range(amount_classes):
                    if (l[i,k,r]==1):
                        classes1[k]=classes1[k]+1
                        ind1=1
                dop_attrib[k]=dop_attrib[k]+reliability[i,r,k]*significance[i]
            break
        else:
            j=j+1
    if (ind==0):
        distance=np.zeros(2, dtype="float32")
        distance[0]=abs(attributes_sample[i]-diapasons[i,0])
        distance[1]=abs(attributes_sample[i]-diapasons[i,amount_zones-1])
        r=0
        if (distance[1]<distance[0]):
            r=1
        for k in range(amount_classes):
            if (l[i,k,r]==1):
                ind1=1
                classes1[k]=classes1[k]+1
                dop_attrib[k]=dop_attrib[k]+reliability[i,r,k]*significance[i]
    for m in range(amount_classes):
        if (dop_attrib[m]==dop_attrib.max()):
            print('end_result:', m+1, 'class')
    print classes1, dop_attrib

amount_zones=6 #число зон для значений признаков

```

```

def forming_diapasons(general_mas_aoi, amount_zones): #формирует диапазоны значений признаков
    amount_classes=general_mas_aoi.shape[0]
    amount_samples=general_mas_aoi.shape[1]
    amount_attributes=general_mas_aoi.shape[2]
    diapasons=np.zeros((amount_attributes, amount_zones+1), dtype="float")
    for i in range(amount_attributes):
        diapasons[i,0]=general_mas_aoi[:, :, i].min()
        diapasons[i, amount_zones]=general_mas_aoi[:, :, i].max()
        step=(diapasons[i, amount_zones]-diapasons[i,0])/amount_zones
        for j in range(amount_zones-1):
            diapasons[i, j+1]=diapasons[i, j]+step
    return diapasons

def forming_massive_l(general_mas_aoi, diapasons): #формирует бинарный массив l
    amount_classes=general_mas_aoi.shape[0]
    amount_samples=general_mas_aoi.shape[1]
    amount_attributes=general_mas_aoi.shape[2]
    l=np.zeros((amount_attributes, amount_classes, amount_zones), dtype="float")
    i=0
    j=0
    for k in range (amount_attributes):
        for i_d in range(amount_zones):
            i=0
            j=0
            while (j<amount_classes):
                if
((general_mas_aoi[j, i, k]>=diapasons[k, i_d])&(general_mas_aoi[j, i, k]<=diapasons[k, i_d+1])):
                    l[k, j, i_d]=1
                    i=0
                    j=j+1
                else:
                    if (i==amount_samples-1):
                        i=0
                        j=j+1
                    else:
                        i=i+1
            return l

def calculation_reliability(general_mas_aoi, diapasons, l): #расчет массивов достоверностей
    amount_classes=general_mas_aoi.shape[0]
    amount_samples=general_mas_aoi.shape[1]
    amount_attributes=general_mas_aoi.shape[2]
    reliability=np.zeros((amount_attributes, amount_zones, amount_classes), dtype="float")
    for k in range(amount_attributes):
        for i in range(amount_zones):
            rel=np.zeros(amount_classes, dtype="float")
            for j in range(amount_classes):
                if (l[k, j, i]==1):
                    sum=0
                    for m in range(amount_samples):
                        if
((general_mas_aoi[j, m, k]>=diapasons[k, i])&(general_mas_aoi[j, m, k]<=diapasons[k, i+1])):
                            sum=sum+1
                    rel[j]=sum*100/amount_samples
            rel1=rel.sum()
            for j in range (amount_classes):
                reliability[k, i, j]=rel[j]/rel1

```

```

return reliability

def significance(general_mas_aoi, diapasons, l): # формирование вектора значимостей признаков
    amount_classes=general_mas_aoi.shape[0]
    amount_zones=diapasons.shape[1]
    amount_attributes=general_mas_aoi.shape[2]
    function_significance=np.zeros(amount_attributes, dtype="float")
    function_significance_norm=np.zeros(amount_attributes, dtype="float")
    sign=np.zeros(amount_classes, dtype="float")
    sign1=np.zeros(amount_classes, dtype="float")
    for k in range(amount_attributes):
        sum=0
        l_mod=np.zeros((amount_classes, amount_zones-1), dtype="float32")
        for j in range(amount_zones-1):
            for m in range(amount_classes):
                p=0
                while(p<amount_classes):
                    if (p<>m):
                        l_mod[m,j]=l_mod[m,j]+l[k,m,j]*l[k,p,j]
                        p=p+1
                    else:
                        p=p+1
            for i in range(amount_classes):
                sign[i]=l[k,i,:].sum()
                sign1[i]=l_mod[i,:].sum()
                sum=sum+sign1[i]/sign[i]
        function_significance[k]=1-sum/(amount_classes*(amount_classes-1))
    for m in range(amount_attributes):
        function_significance_norm[m]=(function_significance[m]-
function_significance.min())/(function_significance.max()-function_significance.min())
    return function_significance_norm

def odn_dwt(signal, LF, HF, delta=0):
    assert(len(LF)==len(HF))
    d=len(signal)
    result=[]
    for k in range(0,len(signal),2):
        wl=0
        wh=0
        for i in range(len(LF)):
            wl=wl+signal[(k+i-delta)%d]*LF[i]
            wh=wh+signal[(k+i-delta)%d]*HF[i]
        result.append(wl)
        result.append(wh)
    return result

def dwt2(image, LF): #ДВП для изображения
    d=len(LF)
    HF=[(-1)**i*LF[d-i-1]
        for i in xrange(d)]
    y,x=image.shape
    image_d=image.copy()
    for i in range(x):
        image_d[i,:]=odn_dwt(image_d[i,:],LF,HF)
    for i in range(y):
        image_d[:,i]=odn_dwt(image_d[:,i],LF,HF)
    image_dwt=image_d.copy()

```

```

image_dwt[0:x/2, 0:y/2]=image_d[0:x:2, 0:y:2]
image_dwt [x/2:x, 0:y/2]=image_d [0:x:2, 1:y:2]
image_dwt [0:x/2, y/2:y]=image_d [1:x:2, 0:y:2]
image_dwt [x/2:x, y/2:y]=image_d [1:x:2, 1:y:2]
return image_dwt

```

```

def razmer(aoi):
    raz=0
    k1=aoi.shape[0]
    k2=aoi.shape[1]
    for i in range(10):
        if ((k1>(2**i))&(k2>(2**i))):
            raz=2**i
    return raz

```

```

def on_bands(rr,rr4,k):
    for l in range(rr4.shape[0]):
        for i in range(k):
            for j in range(k):
                rr4[l,i,j]=rr[j,i,l]

```

```

def razbnadetali(mas):
    m1=mas.shape[1]
    mas_ap=mas[:,0:(m1/2),0:(m1/2)]
    mas_h=mas[:,0:(m1/2),(m1/2):m1]
    mas_v=mas[:,(m1/2):m1,0:(m1/2)]
    mas_d=mas[:,(m1/2):m1,(m1/2):m1]
    return mas_ap,mas_h,mas_v,mas_d

```

```

def preobr(massive,thresh):
    mas=massive
    m0=mas.shape[0]
    m1=mas.shape[1]
    if (m0==m1):
        mas_new=np.zeros((m1,m1), dtype=integer)
        numb_pik=0
        for i in range(m1):
            for j in range(m1):
                if mas[0,i,j]>mas.mean():
                    mas_new[i,j]=1
                    numb_pik=numb_pik+1
    else:
        mas_new=np.zeros((m0,m1,m1), dtype=integer)
        numb_pik=0
        for k in range(m0):
            for i in range(m1):
                for j in range(m1):
                    if (mas[k,i,j]>mas[k,:,:].mean()*thresh):
                        mas_new[k,i,j]=1
                        numb_pik=numb_pik+1
    return mas_new

```

```

def kol_pik(mas01): # характеристики пиков результатов ДВП
    m1=mas01.shape[0]
    m2=mas01.shape[1]
    m_pik=0
    dob=0

```

```

dop=[]
plosh_dob=0
pik=0
plosh=[]
plosh_itog=[]
mas_app=np.zeros((m1,m2), dtype="int")
proverka=np.zeros((m1,m2), dtype="float32")
list_of_lists=form_lists(mas01)
length=len(list_of_lists[0])/2
i=1
n_diap=[]
while (2*i<len(list_of_lists[0])+1):
    n_diap.append(i)
    plosh.append((list_of_lists[0][2*(i-1)+1]-list_of_lists[0][2*(i-1)]+1))
    i=i+1
#print plosh
i=0
while(i<m1-1):
    mas_metka=np.zeros(len(list_of_lists[i])/2, dtype="int")
    j=0
    k=2
    n_diap2=[]
    while(k<((len(list_of_lists[i+1]))+1)):
        k1=0
        k2=2
        metka2=0
        plosh_dob=(list_of_lists[i+1][k-1]-list_of_lists[i+1][j]+1)
        while(k2<(len(list_of_lists[i])+1)):
            if (inter_lists(list_of_lists[i][k1:k2],list_of_lists[i+1][j:k])==True):
                mas_metka[k2/2-1]=1
                n_diap2.append(n_diap[k1/2])
                plosh[n_diap[k1/2]-1]=plosh[n_diap[k1/2]-1]+plosh_dob
                #print plosh[n_diap[k1/2]-1]
                k1=k2
                k2=k2+2
                metka2=metka2+1
                #print plosh
            else:
                k1=k2
                k2=k2+2
        if (metka2>1):
            l_diap2=len(n_diap2)
            while (metka2>1):
                if (((n_diap2[l_diap2-1] in dop) == False)&(n_diap2[l_diap2-
1]<>n_diap2[l_diap2-2])):
                    dob=dob+1
                    dop.append(n_diap2[l_diap2-1])
                    plosh[n_diap2[l_diap2-2]-1]=plosh[n_diap2[l_diap2-2]-
1]+(plosh[n_diap2[l_diap2-1]-1]-plosh_dob)
                    plosh[n_diap2[l_diap2-1]-1]=0
                    p_l,i_l=search_in_list(n_diap2[l_diap2-1],n_diap)
                    for f in range (len(i_l)):
                        n_diap[i_l[f]]=n_diap2[l_diap2-2]
                    if (n_diap2[l_diap2-1]==n_diap2[l_diap2-2]):
                        plosh[n_diap2[l_diap2-2]-1]=plosh[n_diap2[l_diap2-1]-
plosh_dob
                    del n_diap2[l_diap2-1]

```

```

        metka2=metka2-1
        l_diap2=l_diap2-1
    if (metka2==0):
        length=length+1
        n_diap2.append(length)
        plosh.append(list_of_lists[i+1][k-1]-list_of_lists[i+1][j]+1)
    j=k
    k=k+2
    p_m,i_m=search_in_mas(0,mas_metka)
    if (p_m==True):
        v=0
        while(v<len(i_m)):
            #print v
            p_l,i_l=search_in_list(n_diap[i_m[v]],n_diap)
            if (len(i_l)==1):
                pik=pik+1
                #plosh_itog.append(plosh[i_m])
            else:
                if (len(i_l)>1):
                    metka3=0
                    for w in range(len(i_l)):
                        if (mas_metka[i_l[w]]<0):
                            metka3=1
                    pik=pik+1
                    y=len(i_l)-1
                    while(y>0):
                        i_m.remove(i_l[y])
                        y=y-1
                v=v+1
        n_diap=n_diap2
        i=i+1
    p=len(plosh)-1
    while(p>0):
        if ((plosh[p]==0)|(plosh[p]==1)|(plosh[p]==2)):
            plosh.remove(plosh[p])
        p=p-1
    itog=length-dob
    norm=1
    if (m1==32):
        norm=1/4
    if (m1==8):
        norm=4
    if (plosh==[]):
        return 0,0,0
    return len(plosh),mean(plosh),max(plosh)

def search_in_list(x,list1):
    prov=False
    ind_sovp=[]
    for i in range (len(list1)):
        if (list1[i]==x):
            prov=True
            ind_sovp.append(i)
    return prov,ind_sovp

def search_in_mas(x,mas):
    prov=False

```

```

ind_sovp=[]
for i in range (mas.shape[0]):
    if (mas[i]==x):
        prov=True
        ind_sovp.append(i)
return prov,ind_sovp

def form_lists(mas01):
    m1=mas01.shape[0]
    m2=mas01.shape[1]
    spp=[]
    for i in range(m1):
        j=0
        sp=[]
        while (j<m2):
            if (mas01[i,j]==1):
                sp.append(j)
                j=j+1
                if (j==m1):
                    sp.append(j-1)
                    break
            while(mas01[i,j]==1):
                j=j+1
                if (j==m1):
                    break
            sp.append(j-1)
        else:
            j=j+1
        spp.append(sp)
    return spp

def inter_lists(list1,list2):
    if ((list2[0]<list1[0])&(list2[1]<list1[0])|(list2[0]>list1[1])&(list2[1]>list1[1])):
        prov=False
    else:
        prov=True
    return prov

def preobr01(massive,thresh):
    mas=massive
    m0=mas.shape[0]
    m1=mas.shape[1]
    if (m0==m1):
        mas_new=np.zeros((m1,m1), dtype=integer)
        numb_pik=0
        for i in range(m1):
            for j in range(m1):
                if (mas[0,i,j]<mas.mean()*thresh):
                    mas_new[i,j]=1
                    numb_pik=numb_pik+1
    else:
        mas_new=np.zeros((m0,m1,m1), dtype=integer)
        numb_pik=0
        for k in range(m0):
            for i in range(m1):
                for j in range(m1):
                    if (mas[k,i,j]<mas[k,:,:].mean()*thresh):

```

```
mas_new[k,i,j]=1  
numb_pik=numb_pik+1
```

```
return mas_new
```

Приложение С (Справочное)

Копия свидетельства о регистрации программы

РОССИЙСКАЯ ФЕДЕРАЦИЯ		RU 2016613178
		
ФЕДЕРАЛЬНАЯ СЛУЖБА ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ		
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ		
Номер регистрации (свидетельства): 2016613178	Авторы: Назмутдинова Айгуль Илсуровна (RU), Милич Владимир Николаевич (RU)	
Дата регистрации: 18.03.2016	Правообладатель: Федеральное государственное бюджетное учреждение науки Физико-технический институт Уральского отделения Российской академии наук (RU)	
Номер и дата поступления заявки: 2015662110 11.12.2015		
Дата публикации: 20.04.2016		
Название программы для ЭВМ: Программное обеспечение определения разновидностей объектов растительности по их многозональным изображениям		
Реферат: В программе реализован контролируемый метод классификации многозональных космических изображений площадных объектов растительности на основе вейвлет-преобразования. Программа работает в среде Orficks 4.11.0. Программа позволяет принимать решение о принадлежности фрагмента изображения к одному из рассматриваемых классов. В качестве признаков используются численные характеристики результатов дискретного вейвлет-преобразования. Дискретное двумерное вейвлет-преобразование выполняется по схеме Малла. В результате обучения формируется вектор показателей значимости признаков, массивы достоверностей, характеризующие вероятность принадлежности образца к классу, и бинарные массивы, характеризующие распределение значений признаков класса. В результате анализа изображения определяется номер класса, к которому относится исследуемый образец, а также вектор приоритетов, определяющий степень принадлежности образца к каждому из рассматриваемых классов.		
Тип реализующей ЭВМ:	IBM PC - совмест. ПК	
Язык программирования:	Python 2.6.6	
Вид и версия операционной системы:	Windows XP	
Объем программы для ЭВМ:	74 Кб	