

На правах рукописи



**Ньян Линн Тун**

**Алгоритмы классификации данных дистанционного зондирования Земли для  
интерпретации спутниковых и аэрофотоснимков**

Специальность 2.3.1 – «Системный анализ, управление и обработка информации,  
статистика»

**АВТОРЕФЕРАТ**  
диссертации на соискание ученой степени  
кандидата технических наук

Москва – 2022

Работа выполнена в федеральном государственном бюджетном образовательном учреждении высшего образования «Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет)» (МГТУ им. Н.Э. Баумана)

Научный руководитель:

**Бобков Александр Валентинович**,  
кандидат технических наук, доцент  
кафедры систем автоматического  
управления МГТУ им. Н.Э. Баумана.

Официальные оппоненты:

**Дивеев Асхат Ибрагимович** – д.т.н.,  
профессор, главный научный сотрудник  
каф. «Информатика и управление» РАН.  
**Куприянов Андрей Олегович** – кандидат  
технических наук, доцент московского  
государственного университета геодезии и  
картиграфии (МИИГАиК).

Ведущая организация:

Акционерное общество  
**«Военно-промышленная корпорация  
«НПО машиностроения»**

Защита состоится «7» февраля 2023 г. в 16 час. 30 мин. на заседании диссертационного совета 24.2.331.14 при МГТУ им. Н.Э. Баумана по адресу: 105005, Москва, Госпитальный пер., 10, ауд. 613м.

С диссертацией можно ознакомиться в библиотеке МГТУ им. Н.Э. Баумана и на сайте <https://www.bmstu.ru/>.

Отзывы и замечания по автореферату в двух экземплярах, заверенные печатью, просьба высылать по адресу: 105005, Москва, ул. 2-я Бауманская, д. 5, стр. 1 на имя ученого секретаря диссертационного совета.

Автореферат разослан « » 2022 г.

Ученый секретарь  
диссертационного совета

И. В. Муратов

## ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

**Актуальность темы исследования.** В работе рассматривается задача классификации областей и объектов на земной поверхности с использованием данных гиперспектрального дистанционного зондирования Земли (ДЗЗ). Гиперспектральное зондирование позволяет получать информацию как о составе материала объекта, так и о его форме, текстуре и расположении, что позволяет повысить точность обнаружения, распознавания и анализа характеристик наземных объектов. В силу этого, использование гиперспектральных изображений (ГСИ) можно использовать для решения задач, которые не могут быть решены с применением мультиспектральных или обычных цветных изображений с достаточной точностью.

Благодаря своим преимуществам, гиперспектральное зондирование широко используется в самых разных областях. В сельском хозяйстве ГСИ используются в таких областях, как точное земледелие, мониторинг сельскохозяйственных культур и земельных ресурсов. В области охраны окружающей среды ГСИ используется для обнаружения утечек газа, разливов нефти, анализа качества воды, анализа растительного покрова. В биомедицинских приложениях ГСИ используется для тестирования кожи для изучения состояния здоровья человека. Использование данных ДЗЗ для классификации и картографирования растительности позволяют решить эту задачу с минимальными затратами времени и средств. Наличие аэро- и спутниковых гиперспектральных снимков с увеличенным пространственным и спектральным разрешением открывает широкие возможности для классификации и картирования землепользования и растительности. Благодаря большому количеству диапазонов волн, обработка изображений позволяет определять как биохимические, так и структурные свойства растительности.

Для повышения эффективности классификации необходимо разработать классификатор, который должен использовать как спектральную, так и пространственную информацию. Распознавание ГСИ ДЗЗ содержит такие этапы, как коррекция изображения, фильтрация шума, коррекция ракурса, уменьшение размерности и классификация. Для отдельного извлечения пространственной и спектральной информации используется

аппарат сверточных нейронных сетей (СНС). Кроме того, предлагается структура 3D-2D СНС для формирования набора обучающих данных с использованием множества небольших исправлений, взятых из исходных данных.

**Целью работы** является разработка и исследование алгоритмов классификации данных для обработки гиперспектральных данных дистанционного зондирования земной поверхности.

**Основными задачами** являются:

1. Анализ способов повышения эффективности классификации данных ДЗЗ.
2. Исследование типовых структур систем интерпретации данных дистанционного зондирования земной поверхности и основных процедур обработки данных ДЗЗ.
3. Разработка методики и процедуры автоматической классификации данных ДЗЗ.
4. Разработка алгоритмической и программной реализации автоматической системы классификации данных ДЗЗ.
5. Моделирование системы автоматической классификации данных ДЗЗ.
6. Сравнение эффективности разработанного подхода с использующимся методами глубокого обучения для классификации данных ДЗЗ.

**Объектом исследования** диссертационной работы является система компьютерного зрения, осуществляющая автоматическую классификацию гиперспектральных изображений и прогнозирование карты.

**Предметом исследования** является комбинированный подход к решению задачи автоматической классификации гиперспектральных изображений ДЗЗ.

**Методы исследования.** В работе использовались методы цифровой обработки изображений, математической статики, теории глубокого обучения, вероятностных моделей.

**Научная новизна работы заключается в следующем:**

1. Разработан новый подход, основанный на глубоком обучении для эффективного использования спектральной и пространственной информации из гиперспектральных данных и оценки оптимальности классификации гиперспектральных данных с использованием наборов данных Indian pines

(IP) до 99.95%, University of Pavia (PU) до 99.97%, Salinas Scene (SA) до 99.99%.

2. Проведена оценка оптимальности карты прогнозирования с использованием различных пространственных размеров с определением метки классов от каждого пикселя (более точности 99%).

3. Разработана классификационная карта признаков для решения задачи повышения качества изображений прогнозирования дистанционного зондирования.

4. Разработан новый алгоритм, основанный на применении предложенного комбинированного подхода, дающий возможность классификации на высокоразмерных изображениях и на сокращенных наборах данных для автоматической системы классификации гиперспектральных данных дистанционного зондирования Земли.

**Научная ценность диссертационной работы** заключается в предложенном комбинированном способе, основанном на использовании методов классификации данных ДЗЗ, с использованием предварительной обработки и уменьшении размерности входных данных, извлечения пространственно-спектральных признаков, классификации и оценки её эффективности.

**Практическая ценность** диссертационной работы состоит в том, что разработанные алгоритмы в виде программного обеспечения могут применяться в системах автоматической классификации данных ДЗЗ поверхности.

**Достоверность полученных результатов** проведённых исследований подтверждается результатами экспериментов с применением модели системы автоматической классификации ГСИ на основе предложенных методов и алгоритмов.

**Основные научные положения, выносимые на защиту:**

Предлагаемый метод классификации использует не только спектральные сигнатуры, но и пространственную информацию о соседних пикселях для повышения качества распознавания. Основные улучшения в данной работе сводятся к следующему:

1. Комбинированный подход к решению задачи автоматической классификации с использованием существующих моделей для

коррекции яркости, уменьшения шума, снижение размерности и классификации признаков, позволяющий повысить эффективность распознавания системы автоматической классификации ДЗЗ.

2. Алгоритм регуляризации для решения проблемы переобучения и повышения качества карты классификации по сравнению с другими современными методами глубокого обучения.
3. Модифицированная модель классификации ГСИ на основе комбинации разработанных моделей, позволяющие идентифицировать каждый пиксель с эффективностью классификации ГСИ. Для моделирования процесса классификации использовалась среда Python, библиотеки обучения Keras и Tensorflow.
4. Оригинальные структуры и алгоритмы функционирования классификации системы дистанционного зондирования Земли, позволяющие реализовать предложенную методику для стандартных изображений из наборов данных Indian Pines (IP), University of Pavia (PU), Salinas Scene (SA).

### **Внедрение результатов**

Разработанные варианты реализации автоматической классификации ГСИ внедрены на кафедре информационных технологий машиностроения из технологического университета (Тханлин) под руководством министерства образования Союза Мьянмы.

### **Апробация работы**

Результаты диссертационной работы докладывались на следующих конференциях:

1. Международная научно-техническая конференция «Пром-Ижиниринг», (Сочи 2020).
2. IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus) 2021, organized by Moscow, National Research University of Electronic Technology. «MIET», (Зеленоград, 2021).
3. IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus) 2021, organized by Moscow, National Research University of Electronic Technology. «MIET», (Зеленоград, 2021).

4. Всероссийская студенческая конференция «Студентческая научная весна», (Москва, 2018).

### **Личный вклад автора**

Личный вклад автора заключается: в постановке основных задач исследования и разработки процедур их решения; в формировании процедур и методики эффективности качества классификации данных дистанционного зондирования земной поверхности, в компьютерном моделировании разработанных алгоритмов на базе современных программно-технических средств.

**Публикации по теме работы.** По теме диссертации опубликовано 8 научных работ, в числе которых 3 работы в журналах, входящих в список, утвержденный ВАК РФ, 5 в материалах конференций, включенных в базу данных SCOPUS и тезисы доклада на научной конференции.

**Структура диссертации.** Работа содержит введение, четыре главы, заключение, список сокращений-120 наименований, список литературы-103. Объем диссертации изложен на 130 страницах и содержит 42 рисунков, 15 таблиц и 3 листинга.

### **Содержание работы**

**Во введении** содержится обоснование актуальности темы диссертации, формулируются цели и задачи исследования, научная новизна, практическая ценность результатов, а также кратко изложено содержание разделов диссертации.

**В первой главе** приводятся общие сведения о системе автоматической классификации ГСИ ДЗЗ. Описываются процессы формирования нового автоматического шаблона на основе данных, основные принципы построения системы автоматической классификации ГСИ ДЗЗ и постановка задачи автоматической классификации ГСИ ДЗЗ.

Рассматриваются различные проблемы, с которыми приходится сталкиваться в задаче автоматической классификации ГСИ. Рассматриваются способы решения проблемы высокой размерности данных гиперспектрального изображения и отсутствия размеченных образцов. Рассмотрены алгоритмы неконтролируемой классификации и неконтролируемой классификации и объекта на основе анализа изображения. Для решения проблемы больших наборах данных и больших размерах

изображений проведен анализ источников, описывающих способы повышения точности. Для эффективного использования информации, хранящуюся в весах сети, предложена динамическая маршрутизация между нейронами и разработана новая модель сети. В этом случае нейрон организован в вектор, длина и ориентация которого соответственно представляют вероятность существования и свойства объекта.

Проведён аналитический обзор методов классификации ГСИ в системах контролируемой и неконтролируемой классификации. Приведена типовая структура и основные принципы классификации ГСИ ДЗЗ. Рассмотрена задача автоматического классификация ГСИ ДЗЗ. Описана постановка задачи автоматической классификации ГСИ ДЗЗ; рассмотрены методы снижения размерности входных данных, методы извлечение пространственной и спектральной информации, разработан алгоритм определения размера окна классификации, рассмотрены новые точные и эффективные модели классификатора с использованием комбинированных 3D-2D сверточных нейронных сетей. Выполнен обзор этапов проектирования.

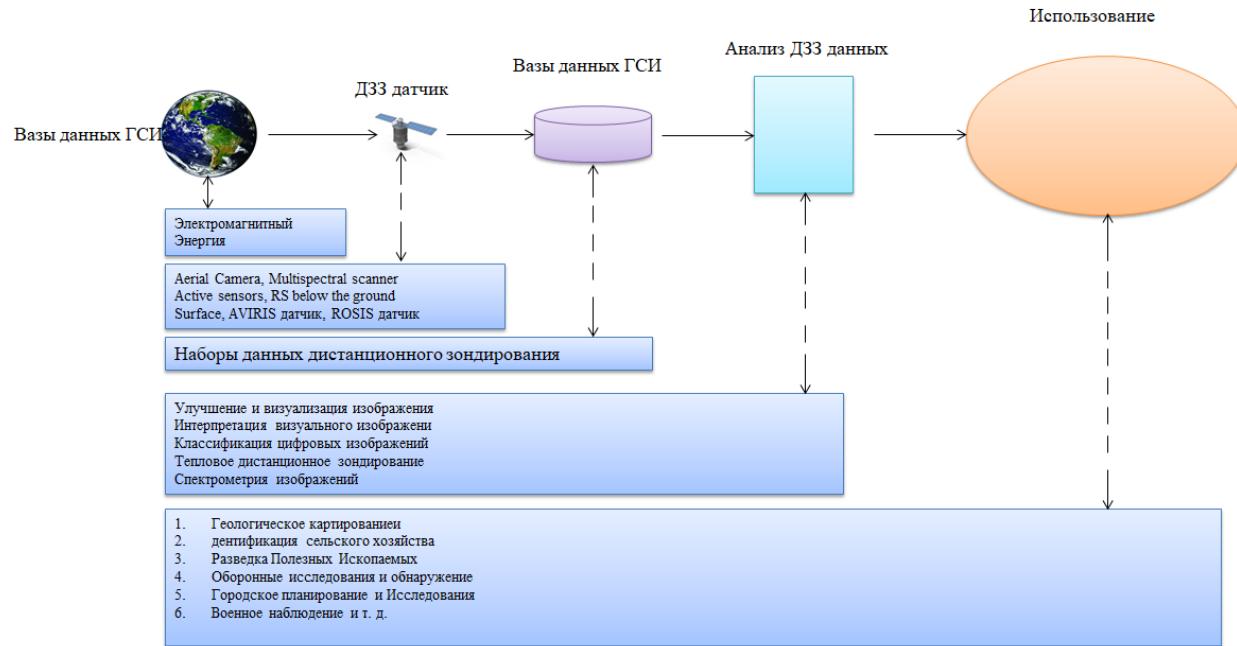


Рис.1. Общая структура системы классификации ГСИ ДЗЗ.

**Вторая глава** посвящена исследованию различных структур СНС для решения задач автоматической классификации ГСИ. Рассмотрены алгоритмы

автоматической классификации ГСИ ДЗЗ, приведены типовые структуры и процедуры СНС. Представлены методы обработки входных данных, таких как уменьшение шума, коррекция ракурса, уменьшение размерности и классификация. Приводится описание методов, используемых в построении предложенной автоматической классификации ГСИ. Рис 2. иллюстрирует представление структуры предлагаемой комбинированной модели в трехмерном -двумерном пространстве признаков и уменьшение полосы спектра из гиперспектральных данных ДЗЗ.

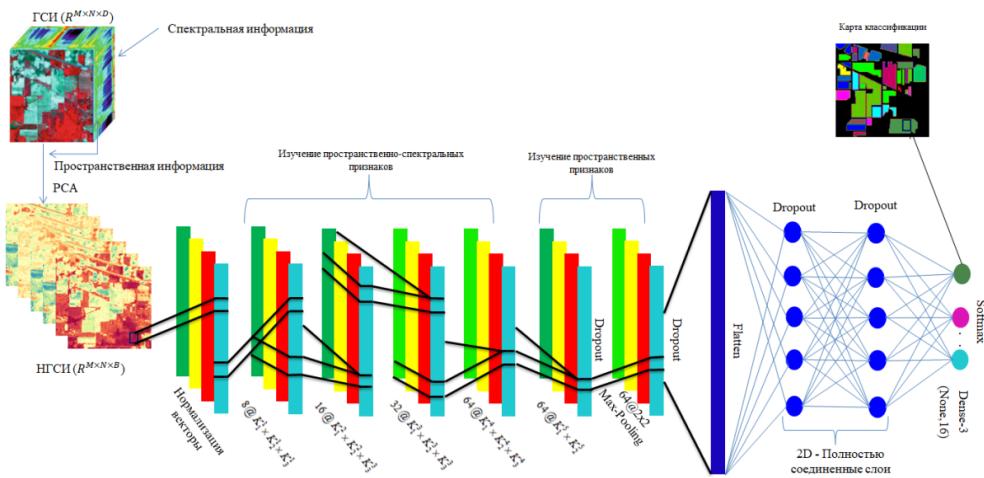


Рис.2. Структура предлагаемой комбинированной 3D-2D модели.

Разработана модель на основе комбинированных 3D-2D сверточных нейронных сетей для решения задачи эффективности автоматической классификации данных дистанционного зондирования Земли.

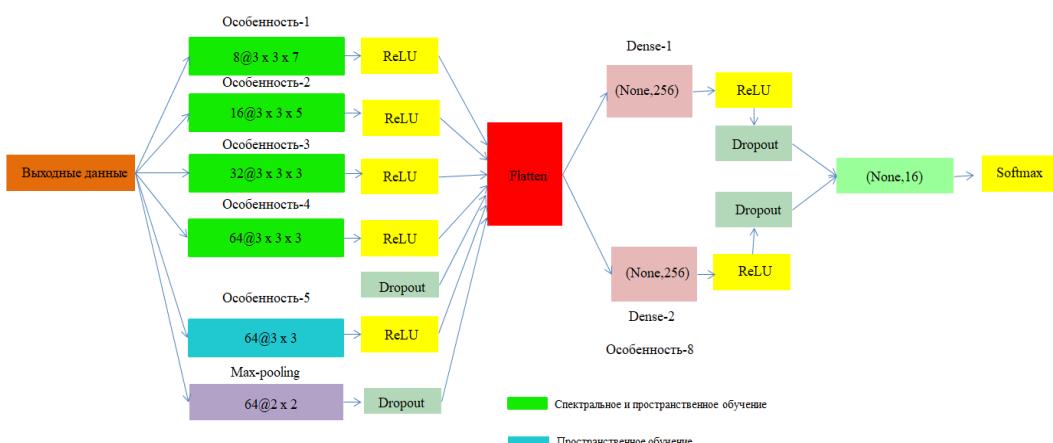


Рис.3. Описание схемы сверточных нейронных сетей (3D-2D СНС ).

Математическая модель сети 3D-2D СНС имеет следующий вид:

$$v_{i,j}^{x,y} = G(b_{i,j} + \sum_{\tau=1}^{d_{l-1}} \sum_{\rho=-\gamma}^{\gamma} \sum_{\sigma=-\delta}^{\delta} \omega_{i,j,\tau}^{\sigma,\rho} \times v_{i-1,\tau}^{x+\sigma,y+\rho}) \quad (1)$$

Уравнение (1) можно рассматривать как 2D свертку, которая генерирует  $v_{i,j}^{x,y}$  карту объектов на особенность признак  $j^{th}$  в пространственном положении  $(x,y)$  на  $i^{th}$  слоя, путем вычисления суммы точечного произведения между входом и 2D фильтр.

$$v_{i,j}^{x,y} = G(b_{i,j} + \sum_{\tau=1}^{d_{l-1}} \sum_{\lambda=-a}^a \sum_{\rho=-\gamma}^{\gamma} \sum_{\sigma=-\delta}^{\delta} \omega_{i,j,\tau}^{\sigma,\rho,\lambda} \times v_{i-1,\tau}^{x+\sigma,y+\rho,z+\lambda}) \quad (2)$$

Уравнение (2) можно рассматривать как 3D свертку, которая может извлекать спектральные и пространственные характеристики представление одновременно из данных ГСИ. Структура предлагаемой комбинированной сети приведена на Рис 3. Она состоит из одной 2D сверток (уравнение 1), трехмерных сверток (уравнение 2), и трех полно связанных слоев. В 3D свертке значение активации в пространственном положении на  $(x,y,z)$ ,  $v_{i,j}^{x,y,z}$  карте объектов  $i^{th}$  слоя обозначается как. Описание математические знаки на уравнение (1) и (2):  $G$  – функция активации,  $b_{i,j}$  – параметр смещения (bias) для  $j^{th}$  – карты пространственных объектов  $i^{th}$  – слоя,  $d_{l-1}$  – количество объектов на карте на  $(l-1)^{th}$  – слоя,  $2\gamma+1$  – ширина ядра,  $2\delta+1$  – высота ядра,  $\omega_{i,j}$  – значение весового параметра для карты пространственных объектов  $i^{th}$  – слоя,  $2a+1$  – глубина ядра вдоль спектральной размерности.

Разработана 3D-2D СНС модель на основе существующей модели СНС для решения задачи классификации ГСИ с сложности высоких размерности данных. Комбинированная 3D-2D СНС модель аналогична Hybrid: SN, за исключением более глубокой сетевой архитектуры (более трёх трехмерных слоев) и использовано четыре модуля регуляризации отсева для уменьшения переобучения и улучшения обобщения глубоких нейронных сетей. Во время

обучения, был использован модуль максимального объединения для уменьшения количества параметров и размеров данных ГСИ.

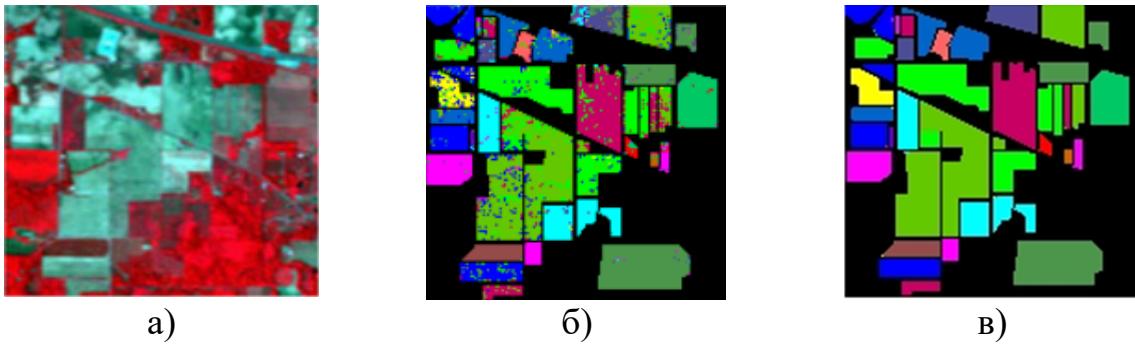


Рис.4. Пример результаты классификационных карт с помощью модели СНС: а) исходное изображение в псевдоцветах, б) изучение только основанными только на спектральной информации, в) изучение глубоких пространственно-спектральных информации.

На Рис 4. представлена исследованные модели СНС с различными архитектурами. Системы автоматической классификации ГСИ зависят от специфического применения технологии автоматического распознавания образов в области дистанционного зондирования. Традиционные классификаторы, являются работами, основанными только на спектральной информации. Эти классификаторы плохо работают из-за спектральной избыточности и высокой корреляции между спектральными полосами. Кроме того, эти классификаторы не в состоянии сохранить важную пространственную изменчивость гиперспектральных данных, что также приводит к низкой производительности. Низкая производительность в модели глубокого обучения обычно вызвана либо чрезмерным, либо недостаточным соответствием данных. В увеличении времени обучения, которое дает недостаточно эффективной модели достаточно времени для определения оптимальных значений ее параметров. С другой стороны, переоснащение происходит, когда модель не может обобщить информацию из набора данных. Он хорошо работает с обучающим набором данных, но плохо работает с новыми данными.

**В третьей главе** приведена раздел наборов базы данных для экспериментальной работы. Как правило, ГСИ содержит более трех полос по

сравнению с обычными изображениями RGB. Гиперспектральные изображения снимаются специализированными дистанционными датчиками на летательном аппарате и собираются из спектральных данных, отраженных наземными объектами в определенном районе Земли. Для работы использовалась три набора данных гиперспектральных изображений, а именно Indian Pines (IP) на Рис 5, University of Pavia (PU) на Рис 6, и Salinas Scene (SA) на Рис 7. Набор данных Indian Pines (IP) содержит изображения с пространственными размерами  $145 \times 145$  и 224 спектральными полосами в диапазоне длин волн от 400 до 2500 нм, из которых 24 спектральных полосы, охватывающих область поглощения воды, были отброшены. Набор данных (IP) обозначается в 16 классы растительности. Пространственная размерная информация набора данных University of Pavia (PU) имеет размерность 610 x 340 пикселей, и 103 спектральных полосы в диапазоне длин волн от 430 нм до 8600 нм. Набор данных PU был разделен на девять классов городского типа подстилающей поверхностью [7]. Функция изображения набора данных Salinas Scene (SA) содержит 512 x 217 пространственных измерений и 224 спектральных диапазона в диапазоне длин волн от 360 нм до 2500 нм. Из этого набора данных SA удалены 20 полос, связанных с водой. Эти наборы данных дистанционного зондирования имеют 3D-куб данных, который состоит из 2D-пространственной информации (функция изображения) и 1D-спектральной информации (спектральные полосы).

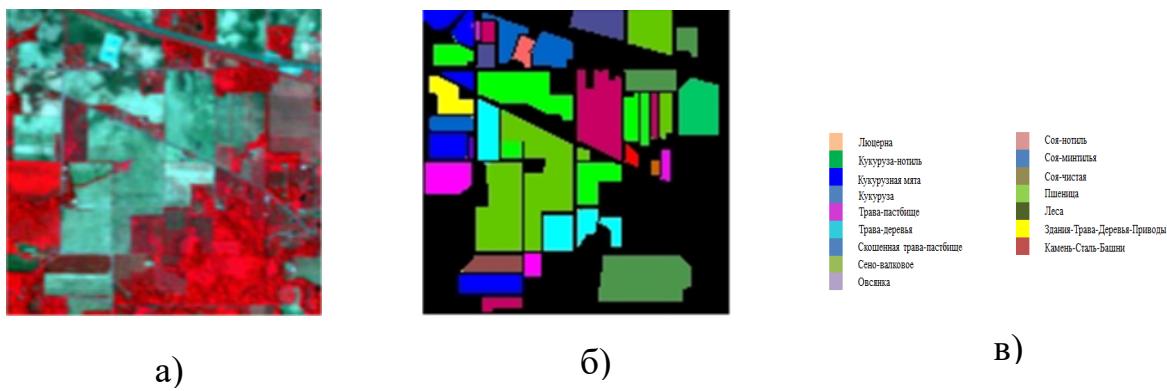


Рис.5. Пример изображения из базы данных Indian Pines: а) исходное изображение в псевдоцветах, б) разметка классов, в) цветовые обозначения классов.

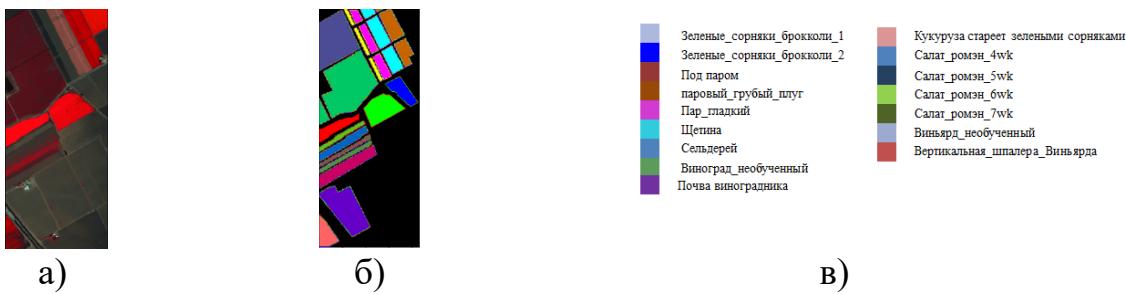


Рис.6. Пример изображения из базы данных Salinas Scene: а) исходное изображение в псевдоцветах, б) разметка классов, в) цветовые обозначения классов.

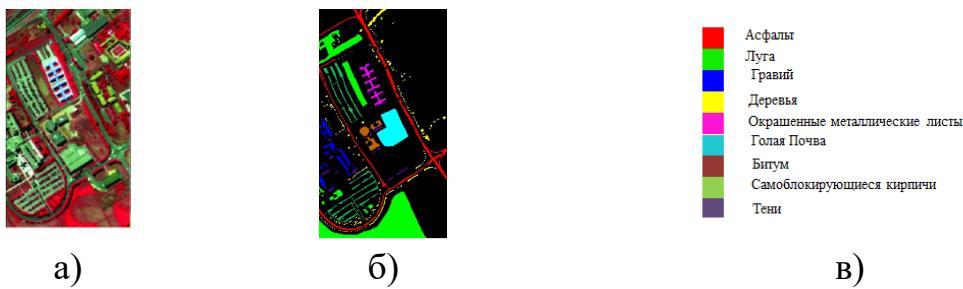


Рис.7. Пример изображения из базы данных University of Pavia: а) исходное изображение в псевдоцветах, б) разметка классов, в) цветовые обозначения классов.

**В четвертой главе** приводятся реализация классификации ГСИ ДЗЗ на основе спектрально-пространственных информационных технологий с использованием комбинированных 3D-2D сверточных нейронных сетей и результаты экспериментальных исследований описанных методов. В начале главы проведено планирование эксперимента. Задача автоматической классификации ГСИ решается для высокой размерности данных гиперспектрального изображения и отсутствие помеченных образцов. Тестирование алгоритма предложенного комбинированного метода проводилось на трёх базы данных: База данных Indian Pine, База данных Salinas Scene, База данных University of Pavia. В разработанной модели системы автоматической классификации гиперспектральных изображений дистанционного зондирования Земли используется уменьшение размера методом главных компонента (PCA), преобразования изображений алгоритмы и метода классификации 3D-2D сверточных нейронных сетей.

Основной проблемой при использовании методов пространственно-спектрального выделения признаков является возможная высокая размерность векторов признаков, используемых классификаторов. Автоматической классификации ГСИ осуществлялось по статическим изображениям прогнозирования с использованием различных пространственных размеров. Блок-схема алгоритма предложенной автоматической классификации ГСИ для повышения эффективности классификации данных показана на Рис 8.

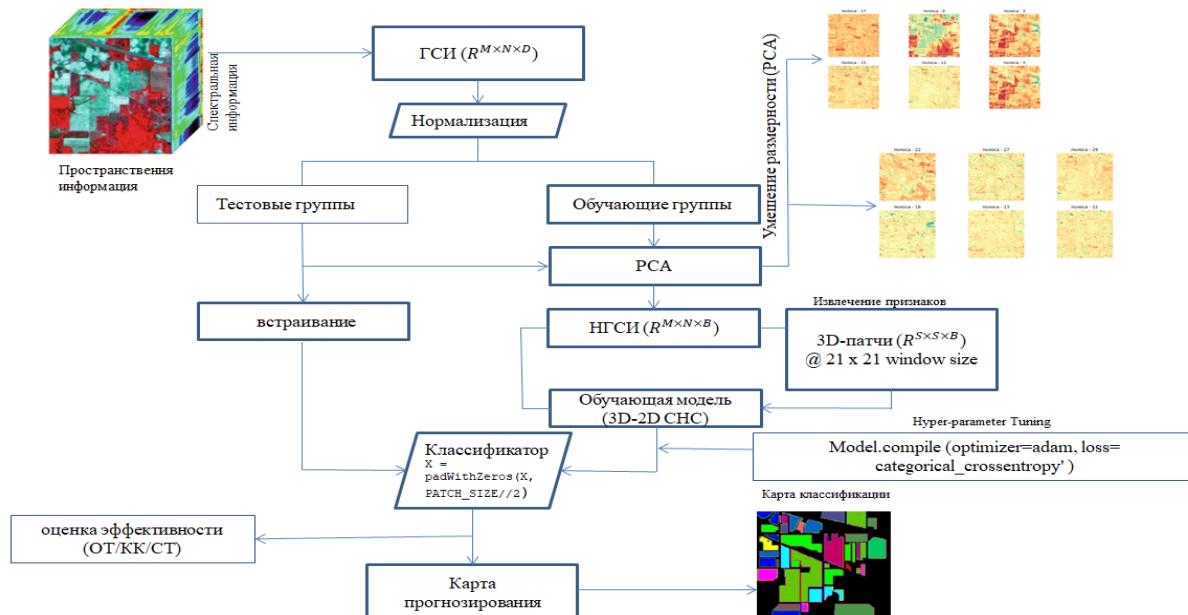


Рис.8. Блок-схема алгоритма системы автоматической классификации ГСИ.

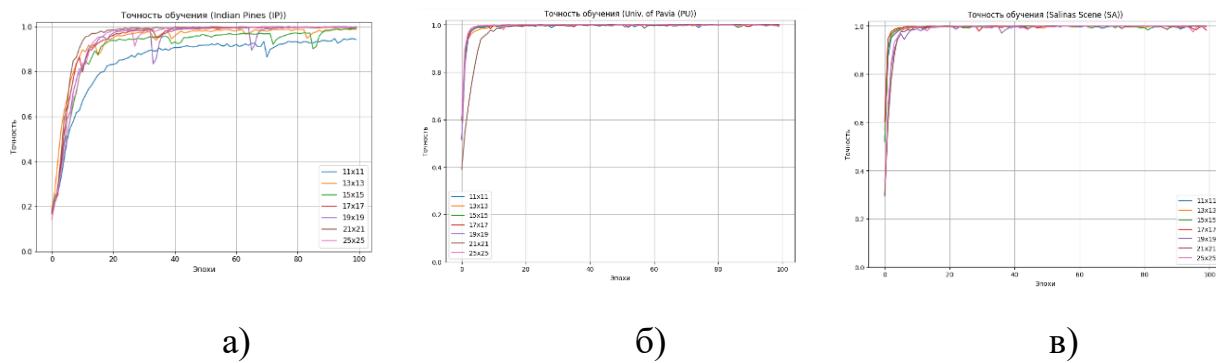


Рис.9. Исследование различных эффективной точности от различных пространственных размеров (11 x 11, 13 x 13, 15 x 15, 17 x 17, 19 x 19, 21 x 21, 25 x 25) (а) IP (б) PU (в) SA.

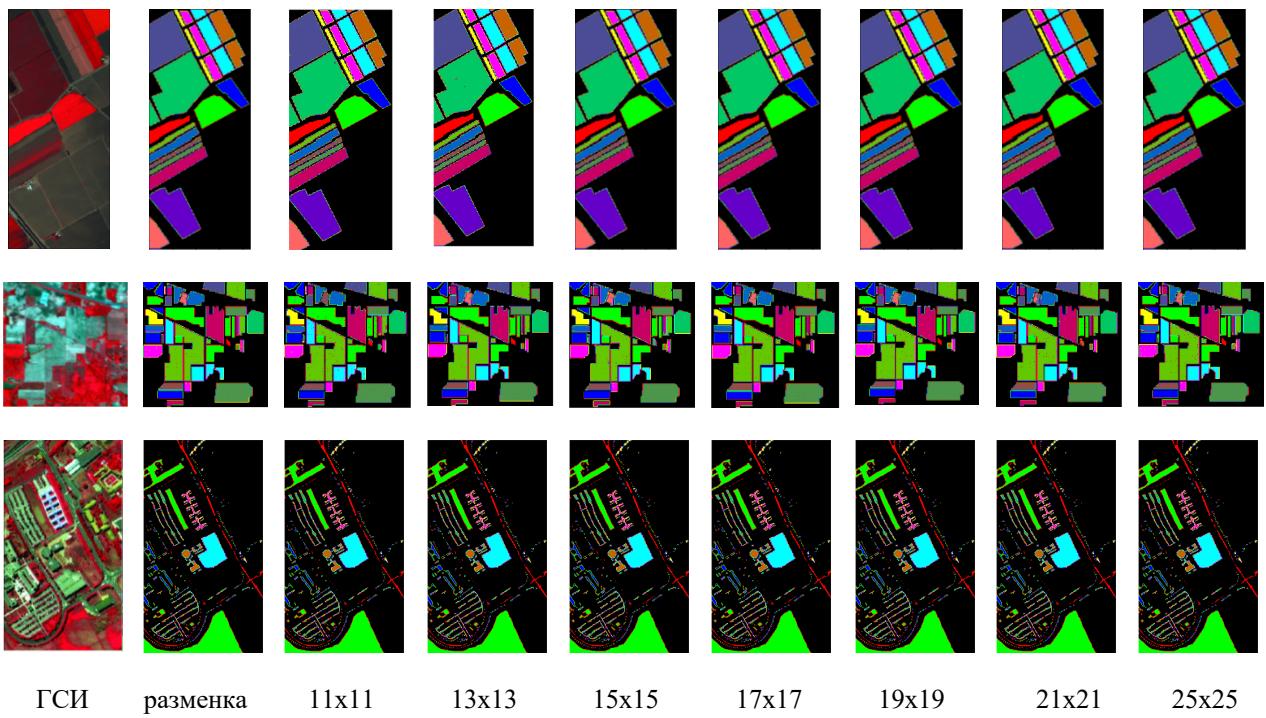


Рис.10. Карты классификации наборов Salinas Scene (верхний ряд), Indian Pines (средний ряд), University of Pavia (нижний ряд), с использованием окна размером размеров (11 x 11, 13 x 13, 15 x 15, 17 x 17, 19 x 19, 21 x 21, 25 x 25) предлагаемой модели 3D-2D CHC.

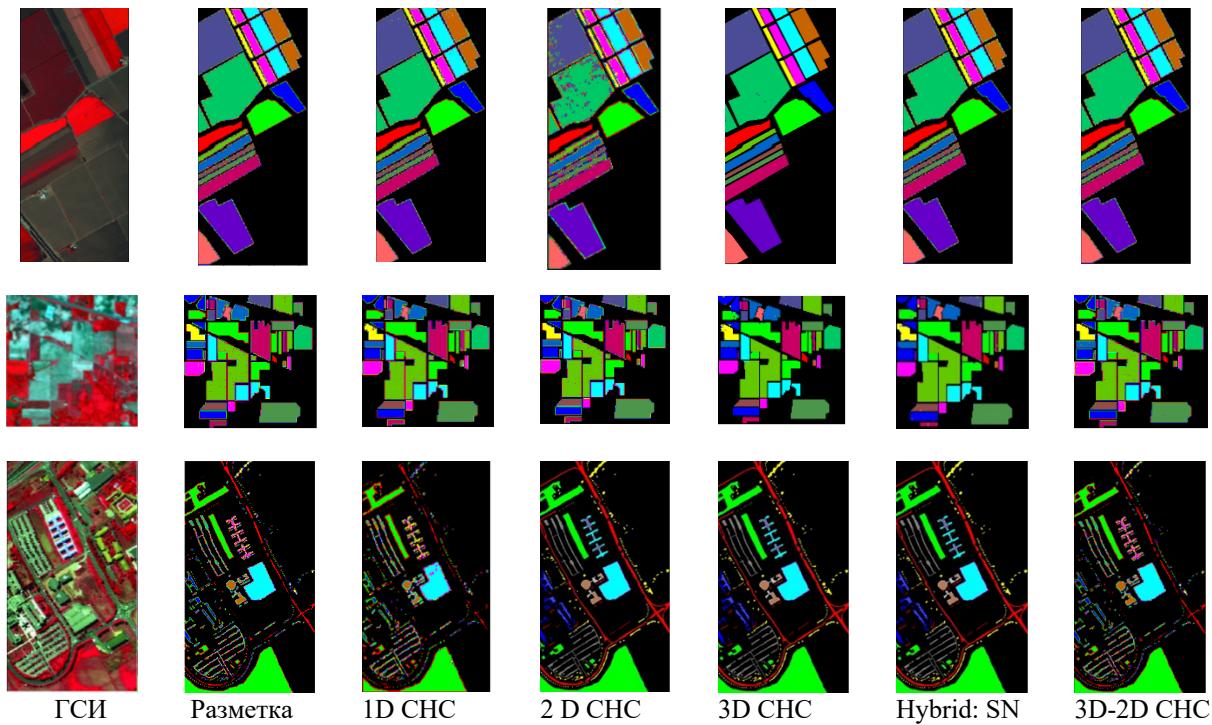


Рис.11. Классификационные карты для набора Salinas Scene (верхний ряд), Indian Pines (средний ряд), University of Pavia (нижний ряд), с использованием разных сверточных нейронных сетей (1D, 2D, 3D, Hybrid: SN, Предлагаемая модель 3D-2D CHC).

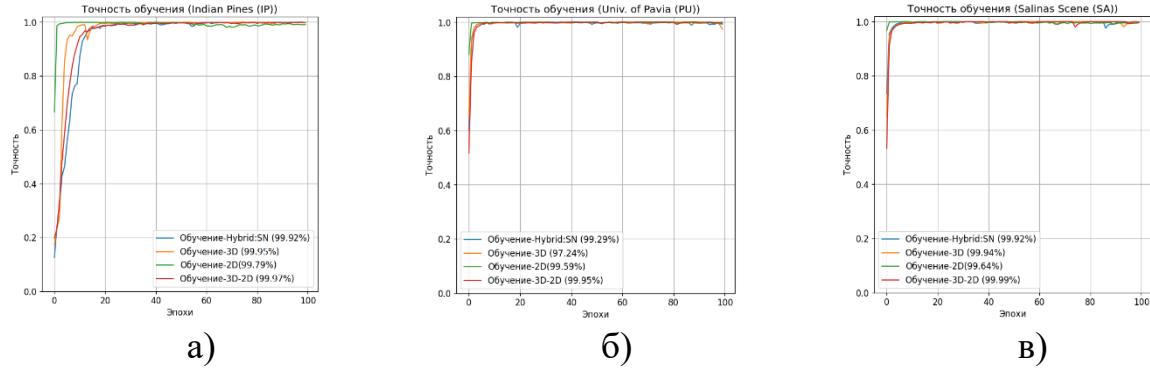


Рис.12. Зависимость глубоких структур сверточных нейронных сетей и использования модулей регуляризации для повышенной вычислительной точности классификации ГСИ ДЗЗ.

*Таблица 1. Точность классификации на уменьшенном объеме обучающих данных 70%*

Методы	Результаты классификации по эталонным трем наборам данных (объеме обучающих данных 70%)								
	Indian Pines			Univ. of Pavia			Salinas Scene		
	ОТ	КК	СТ	ОТ	КК	СТ	ОТ	КК	СТ
1D CHC	99.18 ± 0.0	99.06 ± 0.0	98.85 ± 0.0	99.66 ± 0.0	99.55 ± 0.0	99.50 ± 0.0	99.88 ± 0.0	99.87 ± 0.0	99.91 ± 0.0
2D CHC	99.76 ± 0.2	99.73 ± 0.5	99.03 ± 0.8	99.49 ± 0.2	99.44 ± 0.5	99.78 ± 0.2	99.90 ± 0.2	99.86 ± 0.1	99.78 ± 0.6
3D CHC	98.40 ± 0.0	97.89 ± 0.0	97.89 ± 0.0	98.34 ± 0.0	98.90 ± 0.0	98.91 ± 0.0	98.01 ± 0.0	97.90 ± 0.0	97.68 ± 0.0
Hybrid: SN	99.75 ± 0.1	99.71 ± 0.1	99.63 ± 0.2	99.98 ± 0.0	99.98 ± 0.0	99.97 ± 0.0	100.0 ± 0.0	100.0 ± 0.0	100.0 ± 0.0
<b>3D-2D CHC</b>	<b>99.86 ± 0.1</b>	<b>99.84 ± 0.1</b>	<b>99.44 ± 0.2</b>	<b>99.99 ± 0.0</b>	<b>99.99 ± 0.0</b>	<b>99.99 ± 0.0</b>	<b>100.0 ± 0.0</b>	<b>100.0 ± 0.0</b>	<b>100.0 ± 0.0</b>

*Таблица 2. Точность классификации на уменьшенном объеме обучающих данных 10%*

Методы	Результаты классификации по эталонным трем наборам данных (объеме обучающих данных 10%)								
	Indian Pines			Univ. of Pavia			Salinas Scene		
	ОТ	КК	СТ	ОТ	КК	СТ	ОТ	КК	СТ
1D CHC	97.18 ± 0.0	-	-	99.28 ± 0.0	-	-	99.56 ± 0.0	-	-
2D CHC	97.57 ± 0.0	97.23 ± 0.0	98.46 ± 0.0	99.64 ± 0.0	99.53 ± 0.0	99.74 ± 0.0	98.34 ± 0.0	98.15 ± 0.0	99.33 ± 0.0
3D CHC	82.62 ± 0.0	79.25 ± 0.0	76.51 ± 0.0	94.90 ± 0.0	94.90 ± 0.0	97.03 ± 0.0	85.00 ± 0.0	83.20 ± 0.0	89.63 ± 0.0
Hybrid: SN	98.39 ± 0.0	98.16 ± 0.0	98.01 ± 0.0	99.72 ± 0.0	99.64 ± 0.0	99.20 ± 0.0	99.98 ± 0.0	99.98 ± 0.0	99.98 ± 0.0
<b>3D-2D CHC</b>	<b>99.26 ± 0.0</b>	<b>99.02 ± 0.0</b>	<b>98.03 ± 0.0</b>	<b>99.74 ± 0.0</b>	<b>99.66 ± 0.0</b>	<b>99.27 ± 0.0</b>	<b>100.0 ± 0.0</b>	<b>100.0 ± 0.0</b>	<b>100.0 ± 0.0</b>

## **ЗАКЛЮЧЕНИЕ**

В диссертационной работе решена актуальная научно-техническая задача исследования и разработки алгоритмов автоматической ГСИ для идентификации информации гиперспектральных изображений.

Представленная диссертационная работа в соответствии со своими целями и задачами содержит следующие результаты:

1. Разработан алгоритм классификации типов подстилающей поверхности по ГСИ, способный обучаться на неполных и неточных исходных данных.
2. Разработан подход для решения проблемы переобучения и повышения производительности классификатора. В результате точность классификации повысилась на 0.11% и составила 99.86%, время обучения сократилось в два раза по сравнению с исходной моделью Hybrid : SN.
3. Разработан комбинированный алгоритм с использованием нескольких моделей, позволяющий выполнять классификацию каждого пикселя. Это позволяет повысить точность классификации до 99.95% (PU), 99.97%(IP), 99.99%(SA) и получить прогнозированные карты с лучшими качествами по сравнению с аналогами (1D/2D/3D/Hybrid:SN).
4. По сравнению с аналогами (1D/2D/3D/Hybrid:SN), предложенный метод позволяет использовать существенно меньший объём обучающей обработки (10% от первоначальной базы данных) для достижения 100% точности классификации.
5. На основе предложенных подходов и методов разработано программное обеспечение, позволяющее решать задачу автоматической классификации гиперспектральных изображений.

## **ОСНОВНЫЕ ПУБЛИКАЦИИ ПО ТЕМЕ ДИССЕРТАЦИИ**

1. Ньян Линн Тун, Гаврилов Гаврилов А.И., До Минь Чиен. Классификация гиперспектральных данных дистанционного зондирования Земли с использованием комбинированных 3D-2D сверточных нейронных сетей // Вестник МГТУ им. Н.Э. Баумана. Серия: Приборостроение. 2022. №.1, С.100-118. (0, 73 п.л/0,5 п.л.).

2. Найнг Мин Тун, Гаврилов А.И., Ньян Линн Тун. Автоматизированная система шумоподавления с использованием метода глубокого обучения для распознавания лиц // Современная наука: Актуальные проблемы теории и практики. 2020. Серия Естественные и Технические Науки №6. С . 136-142. (0,72 п.л/0,5 п.л.).
3. Найнг Мин Тун, ГавриловА.И., Ньян Линн Тун. Обнаружения объектов на основе глубоких нейронных сетей в задаче навигации автономного мобильного робота // Современная наука: Актуальные проблемы теории и практики. 2020. Серия Естественные и Технические Науки №6. С . 128-134. (0,74 п.л/0,5 п.л.).
4. Nyan Linn Tun, Alexander Gavrilov, Naing Min Tun, «Multi-Classification of Satellite Imagery Using Fully Convolutional Neural Network» IEEE International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM) 2020. P. 1-5. (0,29 п.л./0,19 п.л.).
5. Nyan Linn Tun, Alexander Gavrilov, Naing Min Tun, Do Minh Trieu, Htet Aung, «Hyperspectral Remote Sensing Images Classification using Fully Convolutional Neural Network» IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus) 2021. P. 2166 – 2170. (0.6 п.л./0.1 п.л.)
6. Nyan Linn Tun, Alexander Gavrilov, Naing Min Tun, Do Minh Trieu, Htet Aung, «Remote Sensing Data Classification Using A Hybrid Pre-Trained VGG16 CNN- SVM Classifier» IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus) 2021. P. 20171 – 2175. (0.6 п.л./0.1 п.л.)
7. Naing Min Tun, Alexander Gavrilov, Nyan Linn Tun, Pyae Phyo Paing, «Face Identification System using Deep Learning Method at Low Lighting Resources» IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus), 2020, P. 2001–2004. (0,31 п.л./0,23 п.л.).