

**САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ**

*На правах рукописи*

**КАРИМОВ САРДОР ИЛХОМ УГЛИ**

**МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ СПУТНИКОВЫХ ДАННЫХ ДЛЯ  
МОНИТОРИНГА НА ПРИМЕРЕ ТЕРРИТОРИИ УЗБЕКИСТАНА**

Научная специальность 2.3.5. Математическое и программное обеспечение  
вычислительных систем, комплексов и компьютерных сетей

**ДИССЕРТАЦИЯ**

на соискание ученой степени

кандидата технических наук

Научный руководитель:  
кандидат технических наук, доцент,  
Гришкин Валерий Михайлович

Санкт-Петербург

2024

## Содержание

<b>ВВЕДЕНИЕ</b> .....	4
<b>ГЛАВА 1. АНАЛИЗ ТРЕБОВАНИЙ К ФУНКЦИОНАЛЬНОЙ СТРУКТУРЕ И ХАРАКТЕРИСТИКАМ СИСТЕМЫ СПУТНИКОВОГО МОНИТОРИНГА ЗЕМЛИ В УЗБЕКИСТАНЕ</b> .....	14
1.1. Особенности сельскохозяйственного производства и основные задачи мониторинга земель .....	14
1.2. Возможности спутниковых средств дистанционного зондирования в решении задач мониторинга сельскохозяйственных земель.....	19
1.3. Урбанизация и расширение городов .....	26
1.4. Требования к функциональной конфигурации и характеристикам спутниковых систем мониторинга сельскохозяйственных земель.....	28
Выводы к главе 1 .....	33
<b>ГЛАВА 2. ИЗУЧЕНИЕ МЕТОДОВ КЛАССИФИКАЦИИ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ</b> .....	34
2.1. Применение мультиспектральных данных среднего и высокого разрешения из области дистанционного зондирования Земли .....	34
2.2. Методы и алгоритмы атмосферной коррекции .....	36
2.3. Спектральные индексы .....	44
2.4. Объектный анализ и классификация изображений.....	47
2.5. Глубокие нейронные сети.....	55
2.5.1. Архитектуры кодер – декодер.....	59
2.5.2. Архитектуры нейронных сетей для сегментации изображений .....	61
Выводы к главе 2.....	66
<b>ГЛАВА 3. РАЗРАБОТКА МЕТОДОВ МОНИТОРИНГА ТЕРРИТОРИИ НА ОСНОВЕ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ</b> .....	68
3.1. Общая структура системы мониторинга районов земной поверхности.....	68
3.2. Мониторимые регионы .....	69
3.3. Методы получения спутниковых данных .....	71
3.3.1. Получение данных с Google Earth Engine в интерактивном режиме....	71
3.3.2. Получение данных с Google Earth Engine в автоматическом режиме....	73

3.3.3. Получение данных с Sentinel Hub в интерактивном режиме .....	75
3.3.4. Получение данных с Sentinel HUB в автоматическом режиме .....	77
3.4. Методы предварительной обработки спутниковых изображений .....	80
3.4.1. Нейронная сеть для атмосферной коррекции спутниковых изображений .....	82
3.5. Нейронная сеть для семантической сегментации спутниковых изображений .....	84
3.6. Методика определения сельскохозяйственных угодий.....	90
3.7. Нейронная сеть для классификации сельскохозяйственных культур.....	93
3.8. Методика обнаружения активной урбанистской территории .....	96
3.9. Оценки качества результатов .....	98
Выводы к главе 3.....	104
<b>ГЛАВА 4. РЕАЛИЗАЦИЯ И ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДОВ МОНИТОРИНГА ТЕРРИТОРИИ НА ОСНОВЕ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ .....</b>	<b>106</b>
4.1. Средства мониторинга территории.....	106
4.1.1. Атмосферная коррекция на основе нейронной сети .....	106
4.2. Нейронные сети для семантической сегментации спутниковых изображений .....	109
4.2.1. Датасет и предварительная обработка .....	109
4.2.2. Обучение сети.....	111
4.2.3. Тестирование .....	113
4.3. Нейронная сеть для классификации сельскохозяйственных культур.....	116
4.3.1. Датасет и предварительная обработка .....	116
4.3.2. Обучение сети.....	117
4.3.3. Тестирование .....	121
Выводы к главе 4.....	125
<b>ЗАКЛЮЧЕНИЕ .....</b>	<b>126</b>
<b>СПИСОК ЛИТЕРАТУРЫ .....</b>	<b>127</b>
<b>ПРИЛОЖЕНИЕ.....</b>	<b>141</b>

## ВВЕДЕНИЕ

В последние десятилетия ученые группы и организации в различных странах активно исследуют возможности спутникового дистанционного зондирования с целью мониторинга окружающей среды. Продвижение технологий дистанционного зондирования существенно расширило возможности практического экологического наблюдения. Полученные данные помогли выявить последствия пожаров, отследить вырубку лесов, наблюдать за изменениями в естественных экосистемах, контролировать использование земли и решать другие проблемы. Особое внимание было уделено разработке систем мониторинга для сельского хозяйства и городских районов. В Узбекистане за последние 15-20 лет произошли значительные изменения в использовании земель по экономическим причинам. Структура использования земли изменилась, и большие участки земли, ранее выделенные под сельскохозяйственное производство, теперь остаются неиспользованными. Необходима объективная информация о преобразованиях в сельскохозяйственном использовании земель [3]. В настоящее время управление землепользованием в основном осуществляется Государственным комитетом Республики Узбекистан по земельным ресурсам, геодезии, картографии и государственному кадастру путем проведения статистических наблюдений. Однако собранная информация имеет общий характер и не подвергается должному контролю за ее достоверностью. В результате существующая система сбора данных о землепользовании не полностью соответствует современным стандартам. Мониторинг изменений в сельскохозяйственном использовании земли становится неотъемлемой частью системы регулирования агропромышленного комплекса [6, 8].

В сфере мониторинга сельского хозяйства Министерство сельского и водного хозяйства Республики Узбекистан и Агентство космических исследований и технологий при Совете Министров Республики Узбекистан совместно работают над созданием собственной системы мониторинга сельского хозяйства на основе

спутников, которая предназначена для получения достоверной информации об использовании сельскохозяйственных земель. Важным элементом этой системы является сбор данных о наличии и использовании пахотных угодий, включая информацию о географическом распределении этих угодий и используемых культурах, а также данные о посевах и оперативный контроль за состоянием посевов. Система призвана предоставлять пользователям информацию о площади пахотных земель, разнообразных сельскохозяйственных культурах, их урожайности и состоянии посевов. Использование данных дистанционного зондирования играет ключевую роль в оценке использования сельскохозяйственных угодий. Снимки со спутников представляют собой дополнительный источник данных, который необходимо регулярно мониторить. Среди важных преимуществ спутниковых снимков следует выделить их своевременность, объективность и независимость. Ранее создание систем оперативного мониторинга затруднялось ограниченным доступом к данным современных спутников, отсутствием необходимого программного и аппаратного обеспечения, а также несовершенством методов тематической обработки изображений. Однако в последние годы появление новых спутниковых систем значительно упростило доступ к данным дистанционного зондирования. Важно отметить, что без соответствующей предварительной обработки и алгоритмов обработки изображений информацию дистанционного зондирования нельзя эффективно использовать [8].

Разработка методов обработки данных дистанционного зондирования для мониторинга сельскохозяйственных культур будет способствовать повышению точности и объективности информации о землепользовании. Это важный этап в создании карт землепользования на основе данных дистанционного зондирования. Учитывая мировой опыт и уровень развития современных систем спутникового мониторинга и компьютерных технологий, разработка методов автоматической обработки и анализа данных спутниковых наблюдений представляется многообещающей. Эта технология играет важную роль в создании системы мониторинга сельскохозяйственных угодий в Узбекистане [2].

Мониторинг сельскохозяйственных угодий включает охват больших территорий и, следовательно, обработку значительного объема данных дистанционного зондирования. Основная цель этого исследования заключается в разработке методов, которые позволят максимально эффективно автоматизировать этот процесс обработки данных дистанционного зондирования. Состояние и динамика землепользования являются ключевыми аспектами современной экологии. Изменения в использовании пахотных угодий могут влиять на микроклимат и ландшафт, что в свою очередь влияет на выбросы углекислого газа.

В последние годы практически все области Узбекистана столкнулись с процессом деградации сельскохозяйственных земель, что привело к эрозии почв, снижению их плодородия и распространению кустарников. Вместе с тем, неурожай является естественным явлением, которое усложняет управление и контроль за сельскохозяйственными угодьями. Например, неэффективное использование земли, включая игнорирование принципов севооборота, может способствовать эрозии почвы, что в конечном итоге приводит к долгосрочному снижению ее плодородия. Поэтому требуется объективный подход к управлению землепользованием как на уровне отдельных сельскохозяйственных районов, так и на государственном уровне [2].

Учитывая важность сельского хозяйства для экологии, экономики и социальной сферы в Узбекистане, а также недостаток объективной, практичной и достоверной информации о пахотных землях, разработка методологии для мониторинга их состояния с помощью спутников становится крайне актуальной и необходимой. Это определяет актуальность представленного исследования.

Как известно, современные демографические прогнозы и тенденции указывают на то, что в ближайшие десятилетия население Земли будет продолжать расти. Одновременно с этим будет расти спрос на природные ресурсы и жизненное пространство. В результате городские территории значительно расширяются, и по всему миру появляются новые поселения и городские агломерации. Поэтому для решения проблем, связанных с текущими и будущими тенденциями урбанизации,

необходимы данные и методы, позволяющие наблюдать и количественно оценивать изменения, связанные с расширением городов. Цель данной работы - разработать аналитическую схему для выявления закономерностей городского роста на основе данных дистанционного зондирования в различных масштабах и пространственно-временных разрешениях. В данной работе также сделана попытка оценить экологические последствия урбанизации с помощью концепции установленных ландшафтных индикаторов, их расширений и сочетаний. Стоит отметить, что урбанизация происходит неравномерно, сильно варьируя в пространстве и времени. Уникальный и зачастую хаотичный рост городских территорий, происходящий в настоящее время, особенно заметен в Центральной Азии. Узбекистан переживает стремительную урбанизацию, особенно с середины 2001 года. Спрос на новые жилые, коммерческие и промышленные земли стимулирует возникновение новых городских центров, что ставит под угрозу устойчивое развитие, создание высокого качества жизни и защиту экологической устойчивости [9].

Многими учеными были предложены различные методы для решения указанных выше проблем. Однако точность этих методов не всегда удовлетворяет предъявляемым требованиям, решает задачу лишь частично и требует значительных вычислительных затрат. Поэтому разработка методов обработки, сегментации и обнаружения объектов на городских и сельскохозяйственных территориях на основе спутниковых данных остается актуальной задачей.

**Цель исследования.** Основной целью диссертационного исследования было разработать методы, алгоритмы и инструменты автоматизации, а также соответствующее программное обеспечение для обработки данных, полученных из спутниковых наблюдений, с целью решения задач мониторинга в сельском хозяйстве и городских районах. Для достижения этой цели были предложены следующие подходы:

1. Разработка алгоритма атмосферной коррекции для формирования наборов спутниковых данных свободных от влияния атмосферных искажений. Этот алгоритм позволит повысить точность сегментации спутниковых

изображений Земли и достоверность получаемых результатов, а также даст возможность унифицировать изображения, получаемых с разных спутников.

2. Разработка метода обработки спутниковых данных для идентификации сельскохозяйственной продукции на сельскохозяйственных территориях. Этот метод позволит провести классификацию по видам продукции, выращиваемой на землях сельскохозяйственного назначения.
3. Разработка метода идентификации городских объектов путем анализа и сегментации спутниковых данных. Этот метод позволит классифицировать объекты, расположенные на урбанистических территориях, а также даст возможность выявлять вновь построенные объекты.
4. Разработка программного обеспечения обработки спутниковых данных для решения сельскохозяйственных задач и мониторинга урбанизации. Это программное обеспечение позволит повысить качество спутниковых данных с помощью атмосферной коррекции, обеспечит получение данных о состоянии сельскохозяйственных территорий и типов сельскохозяйственной продукции, выращиваемых на этих территориях, а также позволит осуществить мониторинг урбанистических территорий.

**Научная новизна.** В работе получены следующие новые научные результаты:

1. На основе подходов глубокого обучения предложен метод атмосферной коррекции спутниковых изображений. Метод позволяет проводить унифицированную атмосферную коррекцию для снимков, получаемых с разных типов спутников.
2. Предложены методы оценки состояния сельскохозяйственных зон и классификации посевов с использованием алгоритмов определения вегетационных индексов и методов глубокого обучения. Методы позволяют получать объективную информацию о распределении и состоянии сельскохозяйственных угодий, выращиваемых культурах, а также о распределении городских земель.
3. Предложен метод, основанный на модификации архитектуры нейронной сети глубокого обучения, который позволяет сегментировать и

идентифицировать объекты на спутниковых изображениях территорий, включая городские и сельскохозяйственные районы. Метод позволяет существенно снизить требования к вычислительным ресурсам, необходимых при решении подобных задач.

**Методы исследования.** В работе используются методы цифровой обработки изображений, методы машинного обучения, методы математической статистики.

**Практическая значимость.** Разработанный метод предварительной обработки данных дистанционного зондирования позволяет получать изображения, свободные от облачности и других мешающих факторов. Полученные изображения используются для решения различных задач дистанционного зондирования. Разработанный метод идентификации сельскохозяйственных культур был использован для получения данных о пространственном распределении озимых культур, подсолнечника и чистых залежных земель в Ферганской области. Результатом данного исследования стало создание важного программного инструмента для национальной системы мониторинга сельскохозяйственных угодий и городских территорий, разрабатываемой в Узбекистане.

**Апробация.** Основные результаты диссертационной работы докладывались и обсуждались на научных семинарах кафедры компьютерного моделирования и многопроцессорных систем Санкт-Петербургского государственного университета, а также на восьми международных научных конференциях:

1. Proceedings of the 9th International Conference "Distributed Computing and Grid Technologies in Science and Education" (GRID'2021), Dubna, Russia, July 5-9, 2021.
2. The 1st International Conference on Problems and Perspectives of Modern Science: Icppms-2021, Tashkent, Uzbekistan, 10–11 June 2021.
3. Modern Methods of Applied Mathematics, Control Theory and Computer Technologies (Pmtukt-2021), Voronezh, Russia, December 14–16, 2021.
4. Digital Region: Experience, Competencies, Projects Bryansk, Russia, November 26–27, 2020.

5. International Scientific Conference Proceedings “Advanced Information Technologies and Scientific Computing” PIT 2021, Samara, Russia.
6. International Scientific and Technical Conference "Advanced Information Technologies" (PIT-2022), Samara, Russia, April 18 - 21, 2022.
7. 10th International Conference "Distributed Computing and Grid Technologies in Science and Education" (GRID'2023), Dubna, Russia, July 3-7, 2023.

**Публикации.** В ходе исследования было опубликовано девять научных трудов, в которых содержатся основные результаты. Все методы обработки данных, программное обеспечение и анализ результатов были разработаны и применены авторами исследования самостоятельно. Перечень публикаций автора:

1. Grishkin, V., Zhivulin, E., Khokhriakova, A., & Karimov, S. DETECTION OF FERTILE SOILS BASED ON SATELLITE IMAGERY PROCESSING // CEUR Workshop Proceedings. – 2021. – С. 251-255.
2. Grishkin V. M., Karimov S. I. Use of satellite imagery and index control to monitor and analyze the agricultural lands of Bukhara region, which is a world historical heritage // AIP Conference Proceedings. – AIP Publishing, 2022. – Т. 2432. – №. 1.
3. Каримов С. И. Структурная стратегия формирования дистанционного мониторинга земель сельскохозяйственного назначения // Современные методы прикладной математики, теории управления и компьютерных технологий (ПМТУКТ-2021). – 2021. – С. 59-62.
4. Karimov S. I., Karimova M. I., Grishkin V. M. General description of the reception and study of data coming through the satellite // Цифровой регион: опыт, компетенции, проекты. – 2020. – С. 1044-1047.
5. Grishkin V. M., Karimov S. I. U. Models and methods of data processing remote sensing // The American journal of engineering and technology. – 2021. – Т. 3. – №. 02. – С. 67-74.
6. Гришкин В. М. и Каримов С.И. Сравнение данных мультиресурсного дистанционного зондирования для вегетационных индексов. – 2021.

7. Каримов С. И. Методы машинного обучения для прогнозирования урожайности с использованием спутниковых изображений sentinel-2 // Международная научно-техническая конференция "Перспективные информационные технологии" (ПИТ-2022). – 2022. – С. 163-169.
8. Grishkin V.M., Karimov S.I. Deep neural network for semantic segmentation of satellite images // H&ES Reserch, 2024, Vol.16, No. 3, P. 12-17.
9. Grishkin V. M., Karimov S. I. Atmospheric correction of satellite images using a neural network // Physics of Particles and Nuclei, 2024, Vol. 55, No. 3, P. 545–547.

Свидетельства о государственной регистрации программ.

1. Свидетельство РФ №2023664858 на программу для ЭВМ «Программа для распознавания и сегментации объектов на спутниковых снимках» (SatObj)»; правообладатель: Федеральное государственное бюджетное образовательное учреждение высшего образования "Санкт-Петербургский государственный университет" (СПбГУ)»; авторы Гришкин Валерий Михайлович, Каримов Сардор Илхом угли.

**Структура и объем диссертации.** Работа состоит из введения, четырёх глав, заключения и списка литературы. Общий объем состоит из 141 страниц. Библиография состоит из 125 наименований.

**Основные научные результаты диссертационной работы:**

1. Разработан и реализован метод атмосферной коррекции для обработки данных спутникового мониторинга сельскохозяйственных и городских земель. Этот метод позволяет получать спутниковые снимки, на которые не влияют свойства атмосферы, а также дает возможность унифицировать изображения, получаемые с разных спутников [1, 7, 125]. Принцип работы нового метода представлен в [125] и в разделе 3.4. Автор внёс 90% вклад в разработку атмосферной коррекции.
2. Разработаны и внедрены методы сегментации спутниковых изображений для мониторинга сельскохозяйственных территорий и классификации сельскохозяйственной продукции, выращиваемой на этих территориях [2, 3,

6, 124]. Процесс сегментации сельского хозяйства по индексу VI и процесс анализа показателей индекса представлены в статье [2-3, 6] и разделах 2.3 – 3.6. На данном этапе вклад автора в получение результатов составил 95%. Процесс выявления и сегментирования видов сельскохозяйственной продукции отражен в разделах 3.7 и [123-124] программы и статьи. Автор внес 85% вклад в результаты проведения экспериментов и определения вида сельхозпродукции посредством нейронных сетей.

3. Для исследования городской и сельской местности разработан и реализован метод обработки спутниковых данных с использованием нейронных сетей глубокого обучения. С помощью этого метода можно идентифицировать определенные объекты как в городских, так и в сельских местностях [1, 4, 5, 123, 124]. Программное обеспечение для обнаружения и мониторинга объектов в процессе урбанизации [123]. В статье [4, 124] и разделах 2.5, 3.8 и 4.2 представлена информация о процессе урбанизации. Автор внес 90% вклада в создание этого процесса сегментации.

С помощью разработанных методов удалось улучшить представление о распределении городских земель в Республике Узбекистан и контролировать сельскохозяйственные угодья, определить качество пахотных земель, определить виды сельскохозяйственных культур, выращиваемых на этих землях [1-7, 123, 124, 125].

#### **Положения, выносимые на защиту.**

1. Метод атмосферной коррекции для обработки данных спутникового мониторинга сельскохозяйственных и городских земель. Этот метод позволяет получать спутниковые снимки, на которые не влияют свойства атмосферы, а также дает возможность унифицировать изображения, получаемые с разных спутников.
2. Методы обработки спутниковых изображений для оценки состояния сельскохозяйственных зон и классификации посевов с использованием алгоритмов определения вегетационных индексов и подходов глубокого обучения.

Метод сегментации и идентификации объектов на спутниковых изображениях территорий интереса, включая городские и сельскохозяйственные районы. Метод основан на модификации архитектуры нейронной сети глубокого обучения и позволяет снизить вычислительные затраты при обработке этих изображений.

# **ГЛАВА 1. АНАЛИЗ ТРЕБОВАНИЙ К ФУНКЦИОНАЛЬНОЙ СТРУКТУРЕ И ХАРАКТЕРИСТИКАМ СИСТЕМЫ СПУТНИКОВОГО МОНИТОРИНГА ЗЕМЛИ В УЗБЕКИСТАНЕ**

## **1.1. Особенности сельскохозяйственного производства и основные задачи мониторинга земель**

Развитие продуктивного сельского хозяйства является важным фактором экономического прогресса в Узбекистане. По данным 2004 года, население, проживающее в сельской местности, составляло 16,3 миллиона человек. Около 8,7 миллиона человек заняты в сельском хозяйстве ежегодно, что составляет около 52% от общей численности занятого населения в стране. Сельское хозяйство представлено примерно 12% сельскохозяйственных предприятий, 75% домохозяйств и "декханских хозяйств", которые вместе производят 62% всей сельскохозяйственной продукции. В то же время 5,5 процента ВВП Узбекистана производится в сельском хозяйстве (2006). Сельскохозяйственный сектор подразделяется на две основные отрасли: растениеводство и животноводство. Растениеводство составляет 55,1% от общего объема производства сельскохозяйственной продукции (в текущих ценах 2004 года). Объем производства основных культур остается стабильным в последние годы, несмотря на постоянное сокращение посевных площадей. Продукция растениеводства используется как для экспорта, так и для внутреннего рынка.

В Узбекистане имеется 20 миллионов гектаров сельскохозяйственных угодий, включая 3,2 миллиона гектаров пашни, 10,5 миллиона гектаров пастбищ, 3 миллиона гектаров залежей и 2,8 миллиона гектаров многолетних насаждений (на 2004 год). Однако не весь фонд пахотных земель фактически используется. В 2004 году было задействовано лишь 12,8 млн гектаров пахотных земель, которые распределялись по следующим культурам: 31% - кормовые, 9% - промышленные, 10% - озимые, 41% - яровые и 10% - овощные. Чистые залежные площади

составили 5 миллионов гектаров. Производство основных сельскохозяйственных культур сосредоточено в нескольких регионах с наиболее благоприятными климатическими условиями. Они расположены в основном в южных регионах, Сурхандарьинской области и Ферганской долине. Растениеводство очень интенсивно почти во всех регионах Узбекистана. На их долю приходится более 50 процентов общей посевной площади [8]. На 15 регионов с наибольшими посевными площадями приходится 73% общей посевной площади Узбекистана (2004). Большая часть пахотных земель занята фермерами, на долю которых приходится 82 процента от общей обрабатываемой площади.



Рисунок 1.1 Состояние развития сельского хозяйства в Узбекистане в 2017-2020 гг

В период с 1996 по 2017 год площадь пахотных земель сократилась на 8 миллионов гектаров (35 процентов). Заброшенные пахотные земли формально все еще являются сельскохозяйственными угодьями, но зачастую уже не пригодны для дальнейшего использования в сельском хозяйстве. В то же время пространственная неоднородность процесса отказа от сельского хозяйства и неэффективность

традиционных систем сбора данных о состоянии агропромышленного комплекса затрудняют своевременное получение необходимой управленческой информации.

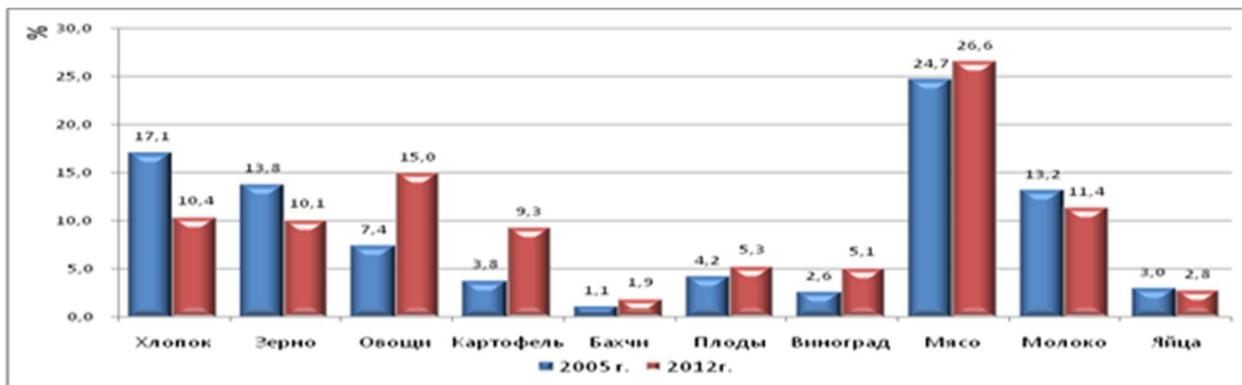


Рисунок 1.2 – Динамика доли отдельных видов сельскохозяйственной продукции в общем объеме сельскохозяйственного производства

Основной причиной сокращения посевных площадей кормовых культур стало резкое снижение производства животноводческой продукции. В то же время посевные площади хозяйственно ценных культур сократились незначительно, а посевные площади технических и других культур увеличились. сравнение структуры посевов с 2010 по 2017 год представлено на Рисунке 1.3. изменения в структуре посевов в основном влияют на плодородие пашни. Ветровая эрозия почвы является предпосылкой снижения плодородия почвы в районах с легким механическим составом почвы и сильным ветром.

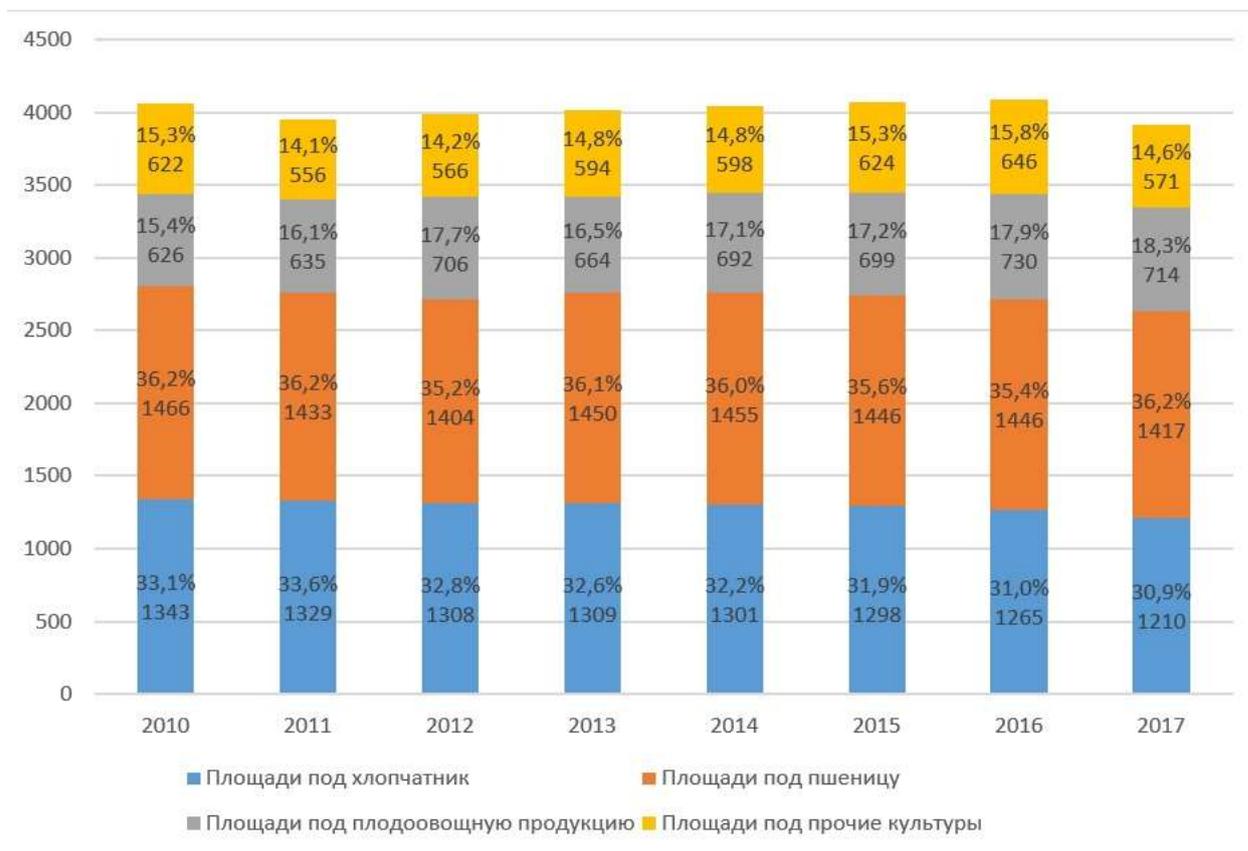


Рисунок 1.3. Распределение сельскохозяйственных угодий, выделенных под посевные площади, сады и виноградники

Тем временем, уменьшение активности использования пахотных угодий оказало благоприятное воздействие на плодородие почв в степной зоне. Изменения в структуре севооборота нарушают научные принципы, связанные с обработкой почвы, и приводят к значительной деградации гумуса, что отрицательно сказывается на плодородии почв.

Изменения в использовании сельскохозяйственных угодий в Узбекистане и нарастающая необходимость в эффективном и устойчивом управлении агропромышленным комплексом на всех уровнях подчеркивают значимость объективной и периодически обновляемой информации о свойствах сельскохозяйственных угодий. В настоящее время сбором такой информации занимается Государственный комитет Республики Узбекистан. К особенностям, осложняющим объективное управление ситуацией в сельскохозяйственном производстве, можно отнести большое количество мелких хозяйствующих

субъектов (агропредприятий) и крайне разрозненное географическое расположение хозяйствующих субъектов. Информация, предоставляемая сельскохозяйственными предприятиями, частично обрабатывается региональными агрономами, но это чрезвычайно трудоемкая задача. Поэтому информация о площади посевов различных культур и других аспектах сельскохозяйственного производства предоставляется сельхозпроизводителями в региональные органы национальной статистики, но отсутствует система проверки достоверности этой информации. Система статистического наблюдения не предоставляет данных о пространственном распределении посевов, поскольку сельскохозяйственные производители сообщают только общую площадь имеющихся и используемых сельскохозяйственных угодий, но не уточняют, какие именно культуры выращиваются на этих угодьях. Таким образом, информация о размещении посевов и фактическом землепользовании не собирается регулярно в традиционных системах сельскохозяйственного мониторинга в Узбекистане. Кроме того, существующие детальные карты землепользования Узбекистана содержат лишь общие сводные данные.

Необходимо эффективно отслеживать изменения в землепользовании. Для организации агропромышленного комплекса также необходима информация о важнейших параметрах сельскохозяйственного производства. Системы сбора подобных данных должны отличаться объективностью, оперативностью, соответствием во времени и пространстве в определении показателей, точностью и высокой степенью независимости от сельскохозяйственных производителей.

Поэтому существует острая потребность в систематически обновляемой и пространственно координированной информации о наличии и реальном использовании пахотных земель на региональном и национальном уровнях. Эта информация должна включать в себя данные о использовании пахотных угодий и их изменениях со временем, площади и состоянии посевов различных культур, а также об изменениях в структуре посевов. Существование систем сбора такой информации, соответствующих современным стандартам, способствует повышению точности и достоверности прогнозов параметров

сельскохозяйственного производства, а также увеличению эффективности информационной поддержки принятия решений в агропромышленном комплексе, включая поддержку агробизнеса через субсидии. Учитывая растущее беспокойство в связи с глобальным изменением климата, точные данные о динамике сельскохозяйственных угодий и структуре землепользования играют ключевую роль в проведении фундаментальных исследований. Совершенствуя системы землепользования, можно разработать оптимальные стратегии для минимизации выбросов углекислого газа в атмосферу.

Для получения более полной и достоверной информации о фактическом использовании сельскохозяйственных земель в 2017 году в Узбекистане был проведен мониторинг сельскохозяйственных угодий. В рамках мониторинга не проводились полевые исследования для сбора информации о пространственном распределении культур, но информация была собрана у крупных фермерских организаций. В связи с высокой стоимостью таких непрерывных исследований, будущие исследования будут проводиться с пятилетним циклом. Таким образом, ежегодно обновляемая информация о состоянии и пространственном размещении сельскохозяйственных угодий будет значимым дополнением к данным, собранным в ходе сельскохозяйственной переписи.

## **1.2. Возможности спутниковых средств дистанционного зондирования в решении задач мониторинга сельскохозяйственных земель**

С самого начала освоения космоса, начиная с первых обычных снимков, сделанных американским спутником ERTS-1 (позже переименованным в Landsat) в 1972 году, и заканчивая спутниковыми системами, созданными различными странами для исследования природных ресурсов, дистанционное наблюдение Земли стало одной из важнейших задач. Данные, полученные в результате дистанционного зондирования со спутников, применяются для различных целей мониторинга Земли, включая сельскохозяйственную съемку. Для мониторинга

растительности наиболее широко используются данные дистанционного зондирования в видимом, ближнем инфракрасном и среднем инфракрасном диапазонах электромагнитного спектра. Спутниковые снимки в этих спектральных диапазонах могут эффективно различать зеленую растительность от других видов растительного покрова. Исследования, проведенные на основе данных наземных и воздушных наблюдений [10,11,12], детально изучили отражательные характеристики сельскохозяйственных культур. Основными факторами, определяющими отражательные свойства растительности, являются присутствие хлорофилла и других фитохромов, структура листьев и компоновка растительного покрова.

Одним из основных аспектов данных дистанционного зондирования является способность обеспечить высокое пространственное разрешение. Такие данные обычно классифицируются на четыре основных категории: данные с низким разрешением (до 1 км), данные со средним разрешением (150-300 м), данные с высоким разрешением (20-80 м) и данные с экстремально высоким разрешением.

Инструмент AVHRR предоставляет изображения земли в шести спектральных каналах с разрешением 1,1 км в надире. Благодаря присутствию нескольких спутников NOAA на орбите, цикл съемки любого участка занимает лишь несколько часов. Получение данных возможно в режиме онлайн через стандартные антенны, а архивные данные предоставляются бесплатно многими государственными и научными организациями. К примеру, архивные данные съемки доступны с 1973 года через геологическую службу США.

В последние годы для получения изображений земной поверхности с умеренным пространственным разрешением (250-500 м) все чаще применяются спутниковые приборы (Terra/Aqua-MODIS, Envisat-MERIS). Эти приборы отличаются наличием многочисленных спектральных каналов и съемкой в узком спектральном диапазоне шириной до 10 нм. Это дает возможность наблюдать полосы поглощения хлорофилла, воды и других значимых компонентов, повышает точность идентификации подповерхностных объектов и оценку их состояния по спектральным характеристикам. Приборы с широкой полосой пропускания

обеспечивают возможность наблюдения за любой точкой земной поверхности в течение одного-двух дней. В районах интенсивного сельского хозяйства Узбекистана, где размеры сельскохозяйственных угодий на несколько порядков превышают пространственное разрешение получаемых данных, необходимо иметь достаточное количество частых наблюдений. Поэтому MODIS предлагает визуализацию данных в 36 спектральных каналах в диапазоне от 0,4 до 14,4 мкм. Пространственное разрешение данных инфракрасных и ближних инфракрасных каналов для мониторинга растительности составляет 250 метров. Спутники Terra и Aqua являются частью экспериментальной программы NASA "Система наблюдения Земли" (EOS).

Запустив программу мониторинга Земли "Copernicus", Европейское космическое агентство (ЕКА) поставило перед собой амбициозную цель - создать сеть спутников, которые будут собирать широкий и разнообразный спектр данных о состоянии Земли. Все эти показатели будут обрабатываться и обобщаться, чтобы получить полную картину происходящих на Земле изменений. Различные группы пользователей получают доступ к интересующей их информации. Sentinel-1A, первый спутник программы Copernicus, находится на орбите с апреля 2014 года. Полностью готовая к работе группировка из двух радарных спутников Sentinel-1 будет получать детальные радарные изображения поверхности Земли и сравнивать их с оптическими изображениями, полученными Sentinel-2. В результате будет получено самое полное и точное изображение поверхности Земли.

Sentinel-2A и 2B — это проекты от Европейского космического агентства (ESA) Sentinel, которые оснащены мультиспектральными оптико-электронными сенсорами, способными получать изображения в видимом, ближнем инфракрасном и коротковолновом инфракрасном диапазонах с разрешением от 10 до 60 метров. Они включают 13 спектральных каналов и 3 спектральных канала и способны выявлять различия в состоянии растительности, включая временные изменения, минимизируя воздействие атмосферных условий на качество изображений. Средняя высота орбиты 785 км и два спутника в полете позволяют повторять изображения каждые пять дней в экваториальных регионах и каждые два-три дня

в средних широтах. Помимо высокой повторяемости изображений, увеличенная ширина захвата позволяет отслеживать быстро меняющиеся процессы, например, изменения в структуре растительности в период вегетации. Миссия Sentinel-2 уникальна сочетанием охвата больших территорий, частых повторных съемок и систематического получения мультиспектральных снимков высокого разрешения с полным покрытием всей Земли. Для бесплатного просмотра, анализа и загрузки изображений, полученных от спутников Sentinel-1, 2 и 3 с низким и средним разрешением, вы можете воспользоваться онлайн-порталами EO Browser и Sentinel Playground. Sentinel Playground представляет собой интерактивный портал, который позволяет просматривать и анализировать мозаики снимков, полученных с помощью спутников Sentinel и Landsat.

Снимки земной поверхности высокого разрешения предоставляются рядом спутниковых систем. Наиболее широко используются спутники серий MSS (Landsat-1, 2, 3, 4 и 5), TM (Landsat-4 и 5) и ETM+ (Landsat-7) Landsat. Самые современные инструменты ETM+ обладают восемью спектральными каналами, охватывающими диапазон от 0,4 до 13 микрон, с разрешением от 15 до 60 метров. Данные от ETM+ доступны на коммерческой основе, однако Университет Мэриленда предоставляет бесплатный доступ к обширному глобальному архиву изображений.

Использование данных дистанционного зондирования для мониторинга сельскохозяйственных земель началось еще в 1970-х годах. Цель мониторинга определяет тип оборудования, используемого для получения данных. Для глобального мониторинга используются спутниковые приборы низкого разрешения, которые позволяют получить данные обо всей поверхности за короткий промежуток времени, но не позволяют собрать информацию об отдельных сельскохозяйственных полях. Данные среднего разрешения имеют высокую частоту наблюдений и пространственное разрешение, что достаточно для мониторинга крупных сельских участков.

Для эффективного решения тематических задач в сельскохозяйственном мониторинге часто требуется предварительная обработка пространственных

изображений. Это особенно важно для обнаружения пикселей, закрытых облаками или покрытых снегом, а также для идентификации пикселей, нарушенных из-за аппаратных сбоев. Ранее выделение безоблачных и чистых изображений осуществлялось вручную операторами, однако с увеличением объема данных дистанционного зондирования возникла потребность в автоматизированных методах и системах предварительной обработки [12]. Предварительная обработка состоит из атмосферных поправок, которые возникают при прохождении отраженного от поверхности Земли излучения через атмосферу.

Из-за высокой размерности анализируемого пространства данных (мультиспектральные изображения разных временных отрезков) полноценная система отслеживания становится невозможной без создания комплекса алгоритмов первичной обработки изображений и интерпретации объектов [11]. Основными задачами здесь являются выбор наиболее подходящих классификационных характеристик и сокращение размерности пространства анализа. В качестве промежуточного этапа сокращения размерности при оценке объема и состояния зеленой растительности могут быть использованы вегетационные индексы (VI). Выбор конкретного индекса зависит от особенностей задачи, которую необходимо решить. К примеру, в источнике [15] производится анализ сопоставления значений вегетационных индексов при использовании различных наборов данных, в то время как в статьях [11, 16] производится сравнение применимости индексов EVI и NDVI, вычисленных на основе этих данных, с чистыми вегетационными индексами. Также в статье [16] описывается возможность определения EVI на основе значений вегетационных индексов. Следует отметить, что для обеспечения сопоставимости значений вегетационных индексов, вычисленных по данным от различных приборов, требуется специальная калибровка полученных спутниковых данных.

Множество исследований, базирующихся на данным высокого разрешения, сфокусированы на анализе применимости дистанционного зондирования на ограниченных территориях. Эти данные могут использоваться для составления карт и оценки состояния основных сельскохозяйственных культур, начиная от

индивидуальных ферм и заканчивая несколькими административными районами [17]. Применение дистанционного зондирования также оказалось полезным для оценки воздействия наводнений на посевы [19]. Исследования, основанные на данных высокого разрешения, представляют собой важный инструмент для изучения различных аспектов применения дистанционного зондирования в сфере точного земледелия.

Потенциал использования данных высокого разрешения активно изучается среди некоторых фермеров в рамках концепции "точного земледелия" [18,19]. Применение дистанционного зондирования помогает фермерам улучшить эффективность использования удобрений, контролировать состояние посевов и оценивать воздействие негативных факторов на урожайность. Информация, полученная с использованием данных высокого разрешения, может быть важным инструментом для оптимизации методов сельского хозяйства [20].

Информация с низким разрешением может предоставить приблизительное представление о росте сельскохозяйственных культур. В таких ситуациях обычно применяется классификация изображений, охватывающая относительно небольшое количество объектов [21]. Эти данные можно использовать для оценки урожайности и определения сроков фенологии растений [22].

В исследовании [23] для картографирования почвенно-растительного покрова сельскохозяйственных территорий применялись данные высокого разрешения (например, MSU-E, HRV-SPOT), среднего разрешения (например, MSU-SK) и низкого разрешения (например, NOAA-AVHRR). Результаты тематической обработки снимков с высоким разрешением предоставляют материал для последующего тщательного анализа снимков среднего разрешения, что может быть распространено на более широкий диапазон. Исследователи приходят к выводу, что использование данных среднего разрешения (Terra-MODIS) представляет перспективу. В литературе также рассматриваются данные высокого (например, Landsat) и среднего разрешения [24, 25]. На базе данных высокого разрешения были разработаны карты разнообразия растительности, в то время как

данные от инструмента MODIS применялись для наблюдения за индексами площади листьев и оценки урожайности разнообразных культур.

Наличие данных среднего разрешения улучшает точность глобального мониторинга по сравнению с данными низкого разрешения в дистанционном зондировании. Эти данные позволяют наблюдать фенологию на отдельных полях в пространственном и временном контексте. В настоящее время активно ведутся исследования по мониторингу сельскохозяйственных культур при помощи приборов среднего разрешения [26,27], и данные от Terra-MODIS применяются для оценки площади посевов риса как на национальном, так и на субконтинентальном уровнях. Применение методов автоматической классификации позволило получить информацию о пространственном распределении посевов риса в нескольких странах Юго-Восточной Азии и Китае. Были проведены оценки площадей посевов, результаты которых хорошо согласуются с официальными данными статистики. Следует отметить, что исследование охватило обширную территорию, простирающуюся на 2,6 миллиона квадратных километров. Методология, примененная для составления карты посевов риса, базируется на априорной информации и анализе динамики посевов. Результаты исследования были сопоставлены с официальной статистикой и результатами классификации снимков высокого разрешения. Аппаратура дистанционного зондирования среднего разрешения способна получать данные по тому же району в течение одного-двух дней. Были предприняты попытки прогнозировать фенологию риса с использованием спутниковых данных [28]. Например, с помощью данных MODIS были предсказаны дата посева риса, дата начала цветения, дата сбора урожая и продолжительность вегетационного периода [29].

Для зерновых культур установлена взаимосвязь между наблюдаемыми с помощью спутника вегетационными индексами и урожайностью [30,31]. Благодаря высокой частоте наблюдений дистанционного зондирования среднего разрешения можно также оценить фактические сроки посева зерновых культур [32]. Однако точность моделирования зависит от качества исходных данных о биофизических

параметрах культуры. Дистанционное зондирование является одним из источников таких данных для моделирования [33,34,35].

### **1.3. Урбанизация и расширение городов**

Урбанизация определяется просто как «перемещение людей из сельских районов в городские, при котором рост населения соответствует городской миграции» (Организация Объединенных Наций, 2005). Урбанизация — это также социальный процесс, который включает в себя изменения в поведении и социальных отношениях в результате проживания людей в городских районах [36]. По сути, оно включает в себя комплексное изменение образа жизни, возникающее в результате воздействия городов на общество [37]. Однако в настоящее время урбанизация обычно используется в более широком смысле и подразумевает гораздо больше, чем просто рост городского населения; оно включает в себя физический рост городских территорий, а также изменения в социально-экономической и политической структуре региона в результате иммиграции населения в городские территории [38,39]. Урбанизация представляет собой динамичное сложное явление, имеющее место во всем мире. Этот процесс, без признаков замедления, привел к значительным изменениям в земном покрове и структуре ландшафта [39,40]. Резкая урбанизация, особенно в развивающихся странах, по-прежнему будет оставаться одной из важных проблем глобальных изменений, влияющих на человеческое измерение [39]. В связи с процессом быстрой урбанизации происходит ускорение пространственного расширения застроенных территорий. Хотя урбанизация способствует социально-экономическому развитию и улучшает качество жизни, рост городов неизбежно приводит к значительным изменениям земельного покрова в городских районах, например, к преобразованию лесов и водно-болотных угодий в сельскохозяйственные или застроенные земли, поскольку для производства используется больше земель. товаров и услуг, а для людей, живущих в городах,

требуется больше жилых земель. Хотя городские территории в настоящее время покрывают лишь 3% поверхности суши Земли [41], преобразования, возникающие в результате роста городов, являются одними из наиболее значительных типов антропогенной динамики земного покрова, а экологические последствия роста городов выходят далеко за рамки городские границы [42,43]. Это особенно актуально в быстро развивающихся регионах, где изменение растительного покрова, вызванное быстрым ростом городов, привело к серьезным проблемам, угрожающим устойчивому развитию городов, например, к местному и региональному изменению климата, изменению гидрологического круга [44].

Процесс роста городов можно охарактеризовать либо как изменение городской площади (мера масштаба), либо как скорость, с которой загородные земли переводятся в городское использование (мера скорости) [45]. Однако масштабы и темпы роста городов не могут дать детальной информации о пространственных моделях урбанизации или лежащих в ее основе процессах. Поэтому городская пространственная структура стала еще одним предметом интереса географов и экономистов при изучении изменения в городах.

В контексте тенденций роста городов большое внимание уделяется разрастанию городов. В конце 1950-х годов явление разрастания городов в США стало широко изучаться. Это рассматривается как явление, сопровождающееся расширением городских территорий с низкой плотностью населения. В дальнейшем аналогичные процессы разрастания городов были описаны в большинстве городов, включая города развивающихся стран.

Из-за его разнообразия и сложности было предложено множество определений разрастания территории. Например, авторы [46] предположили, что разрастание городов происходит, когда земля потребляется более быстрыми темпами, чем рост населения. [47] определили разрастание городов как тип застройки с низкой плотностью населения с разделенными жилыми, коммерческими и промышленными районами, отсутствием процветающих центров деятельности и ограниченным выбором маршрутов путешествий. Аналогичным образом, [48] отметили, что разрастание городов имеет свои особые

пространственные закономерности: неограниченное внешнее и скачкообразное расширение новой застройки с низкой плотностью населения. Хотя не существует общепринятого определения разрастания городов, существует общий консенсус в отношении изображения разрастания городов как особого типа городского расширения, характеризующегося низкой плотностью, рассредоточенной пространственной структурой с экологическими и социальными последствиями [49,50].

#### **1.4. Требования к функциональной конфигурации и характеристикам спутниковых систем мониторинга сельскохозяйственных земель**

В соответствии с Указом о создании Национального космического агентства Узбекистана, принятым в 2019 году, в стране началось формирование национальной системы спутникового мониторинга сельскохозяйственных угодий. Основная цель системы заключается в обеспечении достоверной информации об использовании сельскохозяйственных угодий, включая пахотные земли. Система спутникового мониторинга предоставит Министерству сельского хозяйства и другим государственным и частным организациям объективные данные о сельскохозяйственном производстве. При разработке проекта системы мониторинга были определены следующие основные цели:

1. Составление основной карты показателей использования сельскохозяйственных угодий в течение периода с 2017 по 2022 год;
2. Оценка актуализации данных и динамики использования пахотных земель - по завершении каждого сезона посевов;
3. Определение площади залежных земель - в конце каждого сельскохозяйственного периода;
4. Оценка использования залежных земель - ежегодно в течение 6 недель после завершения сельскохозяйственного сезона;

5. Оценка использования пахотных угодий под многолетние культуры - в конце каждого аграрного сезона;
6. Оценка соблюдения правил севооборота - обновляется ежегодно в конце вегетационного периода;
7. Расчетная площадь под культивацией на текущий год - определяется ежегодно в течение 6 недель с начала сельскохозяйственного сезона и в его завершение;
8. Оценка площади посевов зимних культур - проводится ежегодно осенью, после окончания сельскохозяйственного сезона;
9. Оценка сохранности озимых культур - ежегодно, в течение четырех недель после начала сельскохозяйственного сезона;
10. Мониторинг роста культур в период интенсивного сельскохозяйственного сезона;
11. Прогнозируемая урожайность и общий объем производства основных сельскохозяйственных культур.

Карты обработанных полей Узбекистана должны стать фундаментальной информационной базой для сельского хозяйства. Создание таких карт является отправной точкой для развития дальнейшего мониторинга посевов. Применение алгоритмов обнаружения посевов позволит в будущем проводить оперативный анализ ситуации в сельском хозяйстве. Поэтому первоочередной задачей мониторинга является разработка методов картографирования пространственного размещения пахотных угодий и существующих посевов.

При разработке требований к системам мониторинга обработанных полей учитывались особенности сельского хозяйства. Мониторинг обработанных земель может выполняться с помощью различных устройств дистанционного зондирования, обладающих различными характеристиками, такими как пространственное разрешение, спектральные каналы, частота обновления и другие. Однако для эффективного дистанционного зондирования требуются специальные условия. При мониторинге растительности, например, спутниковые снимки

должны фиксироваться в спектральных диапазонах, наиболее точно разделяющих зеленую растительность от других видов. Пространственное разрешение используемых спутников должно быть достаточным для наблюдения за отдельными полями сельского хозяйства. Сельскохозяйственные культуры растут быстро, требуя постоянного мониторинга. Важным фактором при выборе данных со спутников была их цена. Учитывая, что система мониторинга охватывает все сельскохозяйственные районы Узбекистана, стоимость дистанционного зондирования делает всю систему дорогостоящей. Поэтому одним из ключевых принципов при разработке системы мониторинга было максимальное использование бесплатных данных дистанционного зондирования.

Данные, получаемые от приборов, установленных на спутниках Terra и Aqua, идеально соответствуют этим требованиям. Системы наблюдения обладают спектральными каналами, охватывающими инфракрасную и ближнюю инфракрасную области, а их пространственное разрешение составляет 250 метров. Широкий угол обзора камер позволяет получать снимки территории Узбекистана не реже одного раза в день; кроме того, снимки Landsat-TM/ETM+ были выбраны в качестве дополнительного источника данных с высоким пространственным разрешением.

Из-за большой площади и широкого пространственного распределения обрабатываемых земель одновременное использование нескольких методов визуального дешифрирования пространственных изображений практически невозможно. Большой объем передаваемых данных дистанционного зондирования требует максимальной автоматизации обработки информации, чтобы свести к минимуму участие специалистов. Тем не менее, из-за наличия облаков и других факторов эффективное использование данных дистанционного зондирования для тематического анализа невозможно без предварительной обработки. Алгоритмы предварительной обработки спутниковых данных должны исключать участки поверхности, непригодные для тематического анализа, например, облачные зоны. Предварительная обработка должна гарантировать получение безоблачных изображений для всей зоны мониторинга.

Алгоритмы обработки тематических карт должны быть способны создавать необходимые тематические карты, например, карты распределения культур. Эксперты могут легко определить различные тематические категории с помощью визуального анализа, но разработать автоматические алгоритмы для этой цели очень сложно. Однако без применения автоматизированных алгоритмов практически невозможно выполнить тематический анализ данных о сельскохозяйственных угодьях в Узбекистане. Эти алгоритмы также гарантируют объективность результатов, существенно сокращают время обработки информации и уменьшают потребность в человеческих ресурсах по сравнению с традиционным визуальным анализом. Исходя из вышеупомянутых требований, конфигурация системы мониторинга сельскохозяйственных угодий определяется следующим образом:

1. Подсистемы, отвечающие за сбор спутниковых данных, нацелены на получение, архивирование и каталогизацию необходимых данных дистанционного зондирования. Учитывая обширные объемы данных дистанционного зондирования, эти процессы требуют автоматизации. Наиболее подходящими для мониторинга сельскохозяйственных угодий оказались данные следующих спутниковых систем:
  - Информация среднего пространственного разрешения, полученная через спутниковую систему Sentinel, охватывает весь земной шар за один-два дня. Снимки формируются в видимой и инфракрасной областях спектра. Эти данные идеально подходят для оперативного мониторинга развития растительности.
  - Данные от Sentinel-2 обладают высоким пространственным разрешением. Вопреки этому, они не охватывают сельскохозяйственные угодья с нужной регулярностью, однако могут быть использованы в качестве дополнительных данных к имеющемуся архиву исторических снимков.

2. Роль подсистемы предварительной обработки заключается в подготовке данных перед предметной обработкой. Алгоритмы атмосферной коррекции являются необходимым компонентом этой подсистемы. Такое программное обеспечение должно считывать данные в стандартных форматах, создавать композитные данные и предоставлять запись результатов в наиболее удобном для дальнейшей обработки формате.
3. Важным элементом системы являются алгоритмы обработки объектов для данных дистанционного зондирования. Этот комплекс алгоритмов должен быть в состоянии объективно и надежно определять выбранные категории объектов при минимальном вмешательстве со стороны специалиста. Кроме того, алгоритмы должны демонстрировать надежные результаты для обширных территорий с различными климатическими, рельефными и другими географическими особенностями. Важно также разработать специализированное программное обеспечение для реализации этих алгоритмов.
4. Подсистема получения данных должна позволять пользователю выбирать необходимые данные дистанционного зондирования через простой в использовании интерфейс и получать к ним доступ в кратчайшие сроки. Подсистема распространения должна гарантировать предоставление совокупных изображений, полученных после этапа предварительной обработки, тематических карт и данных, отражающих состояние объектов мониторинга. Информация о результатах мониторинга должна быть архивирована, систематизирована и обеспечивать быстрый доступ. Наиболее эффективным методом распространения информации является предоставление базы данных через Интернет с графическим пользовательским интерфейсом на веб-сайте для удобства пользователей. В то же время специалисты, использующие программное обеспечение, ГИС, должны иметь возможность загружать данные в специализированном формате.

## Выводы к главе 1

Мониторинг использования сельскохозяйственных и городских земель является ключевым фактором для эффективного управления основными секторами экономики. Для обеспечения этой задачи необходимо иметь объективную и актуальную информацию о землепользовании. В настоящее время в Узбекистане активно развивается национальная система мониторинга сельскохозяйственных и городских земель, которая использует данные, полученные с помощью дистанционного зондирования. Основные цели этой системы включают создание карт площадей пахотных угодий, карт годовых посевов, карт для отслеживания состояния посевов, карт для оценки урожайности, карт для мониторинга использования городских земель и карт для планирования размещения объектов. Для достижения этих целей наиболее подходящими являются данные среднего пространственного разрешения, которые обладают достаточной детализацией для оперативного мониторинга на больших территориях, а также данные дистанционного зондирования высокого разрешения, которые используются для исследований на региональном уровне. Однако использование данных ДЗЗ для мониторинга больших площадей сельскохозяйственных угодий в Узбекистане требует разработки систем сбора, обработки и распространения результатов.

Система обработки должна содержать модуль автоматических алгоритмов предварительной и тематической обработки данных, что позволит производить ручную обработку информации сельскохозяйственного мониторинга без привлечения специалистов. Создание автоматизированных алгоритмов предварительной обработки данных дистанционного зондирования обеспечит эффективное использование их для мониторинга урожая, процессов урбанизации и других программ спутникового мониторинга. Необходимо разработать алгоритмы тематической обработки для определения использования пахотных земель, картирования типов культур и мониторинга состояния посевов.

## **ГЛАВА 2. ИЗУЧЕНИЕ МЕТОДОВ КЛАССИФИКАЦИИ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ**

В недавних исследованиях [51], где были использованы данные дистанционного зондирования городских территорий для анализа изменений в ландшафте, отмечается, что сочетание этих данных с пространственными индикаторами может предоставить более детальную и пространственно согласованную информацию о структуре и изменениях городской местности, чем применение каждого метода по отдельности. Также в [52] подчеркивается важность разработки показателей состояния экосистем на основе данных ГИС и дистанционного зондирования с целью смягчения последствий и планирования. Вместе эти инструменты могут значительно улучшить наше понимание изменений и использования ландшафта, что может оказать влияние на городское планирование, улучшив его качество. В следующих разделах представлена история проблемы и последние достижения в исследованиях, касающихся классификации данных дистанционного зондирования в городских районах и использования индикаторов для мониторинга ландшафтов и оценки их воздействия на окружающую среду, включая ландшафтные параметры. Для получения значимых показателей и метрик необходимо аккуратно составить карты землепользования, классифицированные на основе данных дистанционного зондирования.

### **2.1. Применение мультиспектральных данных среднего и высокого разрешения из области дистанционного зондирования Земли**

Информация, полученная из данных дистанционного зондирования, представляет собой важный источник для анализа различных территорий. Эти данные характеризуются высокой пространственной согласованностью и подробной геометрической информацией, а также могут быть получены с высокой частотой на обширных территориях [51]. После проведения классификации данных

дистанционного зондирования возможно извлечь тематическую информацию об изменениях земной поверхности и в использовании земли. Классификация мультиспектральных данных дистанционного зондирования на основе статистических методов распознавания образов является одним из наиболее широко применяемых методов для извлечения информации [53].

Разработано большое множество алгоритмов, среди которых следует отметить параметрические и непараметрические алгоритмы, основанные на статистических методах. Существуют также методы, не требующие параметрических предположений - неметрические подходы, т.е. методы, не использующие метрики расстояния, логические подходы к классификации с наблюдаемыми и ненаблюдаемыми данными, методы классификации с жесткими или нечеткими границами между классами, алгоритмы классификации, ориентированные на пиксели или объекты, методы объектно-ориентированной классификации, гибридные подходы и другие методы классификации. Все эти методы используются для создания карт растительного покрова и землепользования на основе данных дистанционного зондирования [54]. Методы классификации предполагают компромисс между тремя аспектами: количеством спектральной информации в изображении, методом, используемым для определения классификации, и классом информации. Выбор метода классификации зависит от физических особенностей изучаемой территории, предварительных знаний, распределения данных дистанционного зондирования и специфики задачи классификации.

В данном исследовании акцентировано внимание на региональном уровне для всестороннего рассмотрения городской территории и ее окружающей природной среды. Это также ключевой аспект для оценки экологических последствий, так как негативное воздействие фрагментации на биоразнообразие и экосистемные услуги часто наблюдается на промежуточных (региональных) пространственных масштабах. Множество исследований было проведено на уровне региональных территорий, городских агломераций и микрорайонов [56,57,58,59,60], а также на глобальном, континентальном и национальном уровнях

[61,62,63,64,65,66]. Однако до сих пор недостаточно исследований, связывающих урбанизацию с конкретными местными экологическими последствиями, особенно на уровне мегаполисов. Необходимо больше исследований с учетом ландшафтной перспективы [57,64].

Данные низкого разрешения с высокой пропускной способностью, такие как MODIS и AVHRR, подходят для континентальных и глобальных исследований, а данные VHR, такие как Quickbird и Ikonos — для более детальных, мелкомасштабных исследований, например, пригородных районов и конкретных типов местообитаний. Спутниковые данные среднего и высокого разрешения используются для промежуточных региональных подходов, поскольку они обеспечивают наилучший компромисс между пространственным охватом и уровнем детализации.

Прежде чем подвергать спутниковые данные тематической обработке, их необходимо предварительно обработать, чтобы получить реалистичную информацию об особенностях поверхности. Это связано с тем, что отраженное излучение, регистрируемое спутниками, искажается при прохождении через атмосферу. Поэтому первой операцией является устранение этого искажения, известное как атмосферная коррекция.

## **2.2. Методы и алгоритмы атмосферной коррекции**

Коррекция атмосферы при обработке спутниковых изображений — это процесс удаления атмосферных эффектов из измерений, полученных с помощью спутниковых съемочных аппаратов. Цель атмосферной коррекции — устранить атмосферные эффекты, такие как рассеяние света и поглощение излучения, и получить более точные значения радиационных свойств поверхности Земли. Процесс атмосферной коррекции состоит из нескольких этапов [68]:

1. **Измерение излучения.** Получение измерений, записывающих излучение от объектов на Земле. Эти измерения могут включать в себя значения яркости в различных каналах спектра, в зависимости от используемого сенсора.
2. **Оценка атмосферных параметров.** Оценка параметров атмосферы, таких как оптическая толщина, трансмиссия и другие характеристики. Эти параметры могут быть оценены с использованием моделей атмосферы, статистических методов или других техник.
3. **Коррекция измерений.** Применение коррекции к измерениям на основе оцененных атмосферных параметров. Это может включать в себя вычитание влияния атмосферы или другие математические операции для восстановления истинных радиометрических характеристик поверхности.
4. **Восстановление рефлектанса поверхности.** Преобразование скорректированных измерений в рефлектанс, который представляет собой долю излучения, отраженного поверхностью. Рефлектанс является более стабильной и сопоставимой величиной, чем измеренные значения яркости.

Атмосферная коррекция важна для точного анализа и интерпретации спутниковых данных. Она позволяет получить более надежные и сопоставимые результаты при сравнении данных из разных временных и пространственных областей. Существует несколько методов и алгоритмов атмосферной коррекции для обработки космических изображений [69]:

1. **Dark Object Subtraction (DOS):** Часто связывается с Джейсоном Р. Смитом (Jason R. Smith), впервые предложившим концепцию DOS в 1990 году.

$R_{cor} = R_{raw} - D$ , где  $R_{cor}$  - скорректированное отражение,  $R_{raw}$  — измеренное отражение,  $D$  — коррекция.

Основная идея DOS заключается в том, чтобы учесть влияние темных объектов (например, тени) на изображении и скорректировать значения пикселей для улучшения точности данных. Как работает процесс DOS:

- **Определение темных объектов:** DOS начинается с определения объектов на изображении, которые могут считаться "темными". Это

часто включает в себя тени, темные облака, водные поверхности и другие объекты, которые могут вносить темные артефакты на изображение.

- Оценка темных объектов: DOS проводит оценку интенсивности темных объектов на изображении. Это может включать в себя вычисление статистических параметров, таких как среднее значение или медиана темных объектов.
- Вычитание темных объектов: Оцененные значения интенсивности темных объектов затем вычитаются из исходных значений пикселей на изображении. Это позволяет скорректировать измеренные значения, компенсируя влияние темных объектов.
- Калибровка и коррекция: Возможно, требуется дополнительная калибровка и коррекция для учета особенностей атмосферы, света и других факторов, влияющих на изображение.
- Преимущества DOS включают улучшение контраста и качества изображения, а также более точное извлечение информации из пикселей. Этот метод часто используется в контексте обработки данных от спутников наблюдения Земли, таких как данные от Landsat и Sentinel, где атмосферные эффекты могут существенно влиять на качество изображений.

2. **Flat Field Correction:** Также известная как Flat Fielding, — это метод коррекции изображений, который применяется в области оптической и цифровой обработки изображений. Этот метод используется для компенсации неравномерности освещения или чувствительности датчика изображения по всей его поверхности. Как работает Flat Field Correction:

- Получение Flat Field (Flat Frame): Сначала необходимо получить изображение, которое называется Flat Field или Flat Frame. Это изображение обычно представляет собой изображение, полученное при равномерном и интенсивном освещении, при которых объектах на

сцене отсутствуют. Таким образом, любые неравномерности освещения или чувствительности датчика, а также любые артефакты, связанные с оптической системой, могут быть зафиксированы.

- Вычисление Flat Field: Flat Field вычисляется путем усреднения нескольких таких изображений. Важно, чтобы объекты на сцене не создавали теней или изменений в интенсивности на изображении.
- Применение коррекции: Flat Field затем применяется к реальным изображениям сцены. Каждый пиксель в изображении сцены делится на соответствующий пиксель в Flat Field. Это позволяет компенсировать любые изменения яркости или чувствительности датчика, зафиксированные в Flat Field.
- Дополнительная обработка: После применения Flat Field Correction может потребоваться дополнительная обработка, такая как коррекция цвета, выравнивание контраста и другие шаги, в зависимости от конкретных требований задачи.

Применение Flat Field Correction особенно важно в тех случаях, когда качество изображений подвергается влиянию неравномерности освещения или других артефактов, которые могут возникнуть в ходе процесса фотографирования.

3. **Empirical Line Method (ELM):** Джон Роберт Рокс (John Robert Schott) часто связывается с разработкой метода ELM. Это метод, используемый в обработке изображений в удаленном зондировании для коррекции и калибровки данных. Этот метод обычно применяется для улучшения точности и калибровки данных спутников, таких как данные Landsat, Sentinel и других, путем коррекции атмосферных эффектов и других искажений. Для коррекции атмосферного влияния используется линейная регрессия.

$$R_{cor} = m * R_{raw} + b$$

где  $R_{cor}$  - скорректированное отражение,  $R_{raw}$  - измеренное отражение,  $m$  и  $b$  - параметры линейной регрессии. Алгоритм работы метода, следующий:

- Сбор обучающих данных: Сначала собираются обучающие данные для области, которую вы хотите исследовать. Эти данные включают в себя измерения съемки, полученные с датчиков, таких как спектрометры на местности.
- Измерение яркости объектов: Измеряется яркость (отражательность) различных объектов на местности в различных спектральных каналах. Обычно используются несколько каналов для учета различных характеристик поверхности Земли.
- Построение эмпирической линии: На основе измерений строится эмпирическая линия, которая связывает яркость в изображении съемки с измеренной яркостью на местности. Обычно используется линейная регрессия для построения этой линии.
- Калибровка спутниковых данных: Эмпирическая линия затем применяется к данным, полученным со спутника. Это позволяет корректировать значения яркости на спутниковых изображениях, учитывая атмосферные эффекты, углы съемки и другие искажения.
- Проверка и коррекция: Производится проверка точности и, если необходимо, коррекция эмпирической линии. Этот процесс может повторяться для обеспечения наилучшей точности.

Метод Эмпирической Линии широко применяется в области обработки данных удаленного зондирования и обеспечивает мощный инструмент для коррекции атмосферных эффектов и калибровки данных.

4. **Radiative Transfer Models (RTM):** Модели радиативного трансфера (Radiative Transfer Models, RTM) представляют собой математические модели, которые описывают взаимодействие электромагнитного излучения с атмосферой, поверхностью Земли и другими объектами. Широко используются в области удаленного зондирования для анализа и интерпретации данных, получаемых с космических аппаратов и средств аэросъемки. Как работают RTM:

- Атмосферное излучение: RTM учитывает взаимодействие солнечного излучения с различными слоями атмосферы. Это включает в себя рассеяние, поглощение и отражение излучения различными компонентами атмосферы, такими как молекулы, аэрозоли и облака.
- Излучение от поверхности Земли: RTM моделирует взаимодействие солнечного излучения с поверхностью Земли. Это включает в себя отражение, поглощение и испускание теплового излучения, которое зависит от свойств поверхности.
- Передача излучения через атмосферу: RTM учитывает, как излучение, отраженное от Земли, проходит через атмосферу и доходит до датчика на космическом аппарате или самолете.
- Измерения на детекторе: Модель предсказывает, какие измерения должны быть получены на детекторе в результате взаимодействия солнечного излучения с атмосферой и поверхностью Земли.
- Основная сложность RTM заключается в учете разнообразных физических процессов, происходящих в атмосфере, и их взаимосвязи.

5. **MAJA (Multi-sensor Atmospheric Correction and Cloud Screening):** Метод MAJA разработан и поддерживается Французским космическим агентством (CNES) и используется в контексте многих миссий наблюдения Земли, таких как Sentinel-2. Метод MAJA, реализуется в соответствующем программном обеспечении для атмосферной коррекции и выделения облачности в данных, полученных от различных датчиков наблюдения Земли на спутниках. Основные особенности MAJA:

- Атмосферная коррекция: Одной из основных функций MAJA является атмосферная коррекция. Это включает в себя моделирование взаимодействия солнечного света с атмосферой и поверхностью Земли. MAJA учитывает аэрозоли, влажность, озон и другие составляющие атмосферы, чтобы корректировать измерения яркости в соответствии с физическими процессами, происходящими в атмосфере.

- **Выделение облачности:** MAJA обеспечивает выделение облачности (cloud screening), идентифицируя облачные пиксели на изображении. Это важно для того, чтобы исключить облачные области из анализа и обеспечить чистые данные поверхности Земли. MAJA использует различные методы, включая сопоставление с картами облачности, статистические методы и другие.
- **Мультидатчиковая обработка:** MAJA предназначена для работы с данными от разных датчиков, включая Sentinel-2, Landsat и другие. Это обеспечивает универсальность и применимость программы к различным миссиям.
- **Интеграция с другими инструментами:** MAJA может интегрироваться с другими инструментами и платформами обработки данных, что позволяет использовать ее в составе более крупных систем обработки и анализа данных.

MAJA предоставляет устойчивую и надежную атмосферную коррекцию, и обработку облачности для данных спутникового наблюдения Земли, что делает их более пригодными для различных приложений, таких как картография, агрокультуры, экология и многие другие.

6. **Py6S:** Модель 6S разрабатывалась для симуляции воздействия атмосферы на излучение, регистрируемое датчиками на космических аппаратах. Модель учитывает влияние атмосферы на измерения, получаемые от приборов наблюдения Земли на спутниках. Py6S реализуется в виде библиотеки на языке Python, которая предназначена для работы с моделью 6S (Second Simulation of the Satellite Signal in the Solar Spectrum). Py6S обеспечивает программный интерфейс для взаимодействия с моделью 6S, упрощая процесс симуляции атмосферного воздействия на излучение в наблюдаемом спектре. Она может быть полезна для исследований по удаленному зондированию, атмосферной коррекции данных от спутников и других задач.

Каждый метод имеет свои преимущества и ограничения, и выбор зависит от конкретных требований задачи и особенностей данных. Некоторые методы требуют знания атмосферных параметров, таких как оптическая толщина, влажность и т.д., в то время как другие могут быть менее требовательными к внешним данным, но менее точными.

Среди существующих программных средств реализующих, в том числе атмосферную коррекцию, следует отметить программное обеспечение Sen2Core. Sen2Core — это программный инструмент, разработанный для обработки данных от спутников Sentinel-2, принадлежащих Европейскому космическому агентству (ESA). Он является частью обширной системы Copernicus, предоставляющей свободный доступ к данным Sentinel и другим космическим данным для общественности и научных исследований. Sen2Core предоставляет инструменты для обработки данных Sentinel-2, включая следующие функции:

1. Коррекция радиационных ошибок: Sen2Core включает в себя процессы коррекции атмосферных эффектов, таких как аэрозоли и водяной пар, что позволяет получить более точные измерения излучения.
2. Геометрическая коррекция: Инструмент предоставляет средства геометрической коррекции, включая улучшенную регистрацию изображений и устранение геометрических искажений.
3. Обработка различных продуктов: Sen2Core способен обрабатывать различные продукты, включая уровень высокого разрешения (Level-1C) и уровень верхнего уровня (Level-2A).
4. Интеграция с инструментами обработки данных: Sen2Core может использоваться в различных средах обработки данных, включая графический интерфейс пользователя (GUI) и командную строку.

Как правило, тот или иной метод атмосферной коррекции реализуются как часть программного обеспечения соответствующих центров обработки данных для каждого семейства спутников. Эти центры обработки предоставляют пользователям спутниковые снимки с различными уровнями обработки, в том

числе и снимки, для которых проведена атмосферная коррекция. Однако атмосферная коррекция проводится далеко не для всех данных, получаемых со спутников. Например, для спутников Sentinel-2 атмосферная коррекция отсутствует для большого количества снимков, полученных ранее 2018 года. При этом пользователи могут самостоятельно провести предварительную обработку интересующих их данных, включающую атмосферную коррекцию, с использованием соответствующих прикладных программ. Однако эта обработка осуществляется интерактивно для каждого изображения конкретной области, что не позволяет автоматически обрабатывать достаточно большие наборы таких изображений. Поэтому в данной работе предлагается метод позволяющий автоматизировать процесс атмосферной коррекции «сырых» спутниковых изображений при помощи простой сверточной нейронной сети, реализующей архитектуру кодер - декодер. На вход этой сети поступают изображения без атмосферной коррекции, а результатом ее работы будут изображения с атмосферной коррекцией. Сеть обучается на датасете, сформированном из изображений земной поверхности с уже осуществленной атмосферной коррекцией и изображений тех же районов без неё. Предлагаемый метод рассматривается далее в третьей главе работы.

### **2.3.Спектральные индексы**

Спектральные индексы представляют собой числовые характеристики, полученные из данных об отражении различных диапазонов длин волн электромагнитного спектра от земной поверхности. Эти индексы используются в различных областях, таких как сельское хозяйство, экология, геология для оценки различных параметров наблюдаемых территорий с использованием спутниковых или аэрокосмических данных. Кроме того, они могут использоваться для предварительной сегментации полученных изображений по типам земной поверхности. Эти индексы обычно вычисляются с использованием значений из

различных областей спектра, таких как видимый свет, инфракрасные и ультрафиолетовые области. Ниже приведены значения условных символов, используемых в формулах [1]:

- NIR - значения пикселей из ближнего инфракрасного канала.
- RED - отражение в красной области спектра.
- SWIR – значения пикселей из коротковолнового инфракрасного канала.
- L - значение зеленого растительного покрова. Его часто используют в пустынных районах, где растительный покров незначителен, и результаты варьируются от -1,0 до 1,0.
- BLUE – значения пикселей из синего канала.
- GREEN - значения пикселей из зеленого канала.

При обработке спектральных данных, получаемых в ходе дистанционного зондирования Земли, наиболее часто используют следующие спектральные индексы:

1. **NDVI (Normalized Difference Vegetation Index):** Оценка здоровья растительности. Зеленые растения сильно поглощают свет в красном (Red) и ближнем инфракрасном (NIR) диапазонах, что делает NDVI полезным для мониторинга роста растений.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

2. **EVI (Enhanced Vegetation Index):** Аналог NDVI, но с коррекцией на атмосферные условия и влияние почвенного фона.

$$2.5 \times \frac{(NIR - RED)}{(NIR + 6 \times RED - 7.5 \times BLUE + 1)} \quad (2)$$

3. **NDWI (Normalized Difference Water Index):** Определение водных тел, таких как озера и реки. Вода сильно поглощает в ближнем инфракрасном (NIR), в то время как растительность обычно отражает.

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR} \quad (3)$$

4. **NDSI (Normalized Difference Snow Index):** Обнаружение снега и льда. Снег сильно отражает в зеленом и коротковолновом инфракрасном (SWIR) диапазонах.

$$NDSI = \frac{GREEN - SWIR}{GREEN + SWIR} \quad (4)$$

5. **SAVI (Soil-Adjusted Vegetation Index):** Коррекция для почвенного фона, что делает его более чувствительным к изменениям в плотности растительности.

$$SAVI = \frac{NIR - RED}{(NIR + RED + L) \times (1 + L)} \quad (5)$$

где L - константа (обычно 0.5).

6. **MSAVI (Modified Soil-Adjusted Vegetation Index):** Коррекция для почвенного фона с учетом более высокой чувствительности к зеленой растительности.

$$MSAVI = 0.5 \times (2 \times NIR + 1 - \sqrt{(2 \times NIR + 1)^2 - 8 \times (NIR - RED)}) \quad (6)$$

Спектральные индексы широко применяются в различных областях, включая сельское хозяйство (для мониторинга посевов), экологию (для отслеживания изменений в растительном покрове), геологию и дистанционное зондирование. Расчет этих индексов помогает выделить особенности объектов, которые могут быть трудно определить при простом визуальном анализе изображений. В исследованиях, направленных на анализ сельскохозяйственных угодий, были использованы спектральные индексы, включая NDVI и SAVI, с целью идентификации и мониторинга земель сельскохозяйственного назначения в Узбекистане. Кроме того, индексы SAVI, NDVI и EVI были применены для определения и предварительной оценки уровня плодородия и продуктивности сельскохозяйственных угодий. Индекс NDSI можно использовать для определения наличия снежного покрова в горных районах. Эти индексы могут быть также использованы для оценки эффективности орошения, определения оптимального времени сбора урожая и решения других сельскохозяйственных задач. Их применение в сочетании с современными данными дистанционного зондирования

и спутниковыми изображениями позволяет более точно и эффективно управлять сельскохозяйственными угодьями. Таким образом вегетационные индексы можно использовать как информативные признаки для системы распознавания типов сельскохозяйственных культур и степени их развития [2].

## **2.4. Объектный анализ и классификация изображений**

Объектный анализ и классификация изображений — это методы обработки изображений и анализа данных, которые ориентированы на выделение и идентификацию объектов (объекты могут быть домами, деревьями, автомобилями и т.д.) на изображении вместо простого классификации отдельных пикселей. Многие исследования показали, что объектно-ориентированный анализ изображений (OBIA) с использованием спутниковых снимков среднего и высокого разрешения превосходит традиционную классификацию на основе пикселей в городских условиях [70,71,72,73,74,75]. Объектно-ориентированный анализ изображений (OBIA), иногда называемый сегментацией изображений, представляет собой процесс разделения изображения на пространственно смежные, не перекрывающиеся однородные области (также известные как объекты), основываясь на параметрах цвета, формы и масштаба. Кроме того, объекты, созданные на основе пространственной информации, скорее соответствуют реальным структурам или областям на местности, чем отдельным пикселям [76]. Их главное преимущество заключается в том, что правила принятия решений обычно определяются знаниями человека-аналитика, а не компьютерными алгоритмами [55], а слияние различных типов данных позволяет повысить точность [70]. В исследовании [77] было проведено сравнение 13 методов наблюдения, при этом выяснилось, что во всех случаях методы классификации на основе объектов оказались лучше, чем методы классификации на основе пикселей, основанные только на спектральных данных.

В частности, в ряде исследований было показано, что OBIA успешно применяется к данным SPOT для различных целей [78,79,80,81,82,83,84,85]. В 2014 году [86] было проведено тестирование двух методов классификации на основе объектов (KNN и SVM). В ходе тестирования было обнаружено, что оба метода работают лучше, чем пиксельные методы (DT) для картографирования LULC. В литературе [87] четко показаны преимущества использования объектно-ориентированных методов классификации знаний на снимках городской среды SPOT 5 по сравнению с пиксельными методами. Среди нескольких сравниваемых методов первый имел самую высокую точность в создании и выделении значимых объектов, таких как дороги и здания. В [75] выявили улучшение возможностей OBIA по определению границ городов в региональном масштабе с помощью данных SPOT. Также было продемонстрировано преимущества объектно-ориентированного подхода по сравнению с оценкой фрагментации леса на основе пикселей [88]. Статистическое управление Швеции (2008) использовало данные OBIA и SPOT 5 для классификации городских зеленых насаждений, а Шведское агентство по охране окружающей среды использовало эти же данные для классификации природных типов [89].

Анализ и классификация изображений на объектном уровне представляют собой методы обработки изображений, ориентированные на анализ и интерпретацию содержания изображений с учетом объектов, а не отдельных пикселей. Этот процесс проходит через ряд этапов:

- сегментацию изображений;
- извлечение признаков объектов;
- классификацию объектов.

Дадим краткую характеристику каждого из этих этапов.

**Сегментация изображений** — это процесс разбиения изображения на отдельные сегменты или области с целью упрощения анализа. В контексте компьютерного зрения и обработки изображений, это означает разделение изображения на группы пикселей, которые имеют схожие характеристики или

обладают однородной структурой. Цель сегментации изображений включает в себя [90]:

1. Выделение объектов. Сегментация помогает выделить конкретные объекты или области интереса на изображении. Это может быть полезно, например, при автоматическом распознавании объектов, таких как автомобили, лица или другие.
2. Улучшение анализа. Разделение изображения на сегменты облегчает анализ каждой области независимо. Это полезно при изучении свойств различных частей изображения или при применении различных методов обработки к каждому сегменту.
3. Упрощение задач машинного обучения. В задачах машинного обучения, таких как обучение модели для распознавания объектов, сегментированные изображения могут использоваться для обучения модели на уровне сегментов, что может улучшить точность и эффективность.

Существует несколько методов для сегментации изображений, включая пороговую сегментацию, кластеризацию, методы, основанные на границах объектов и глубокое обучение, включая семантическую и инстанс-сегментацию.

1. Пороговая сегментация — основана на применении порога для яркости или цвета пикселей для их разделения на объекты и фон.
2. Кластеризация — группирует пиксели на основе их схожести в пространстве цветов или текстур.
3. Семантическая сегментация — присваивает каждому пикселю метку класса, что позволяет выделить сегменты, соответствующие конкретным объектам.
4. Инстанс-сегментация. Она отличается тем, что различает не только классы объектов, но и каждый отдельный экземпляр объекта.

**Извлечение признаков объектов (Feature Extraction)** — это процесс выделения характерных особенностей или свойств объектов на изображении или в других типах данных. Эти признаки представляют собой информацию, которая может быть использована для описания объектов и, часто, для последующего

анализа или обработки данных. Извлечение признаков объектов играет важную роль в задачах распознавания образов, классификации объектов и других сценариях. Некоторые ключевые аспекты этого процесса включают [90]:

1. Выбор признаков, который включает в себя определение, какие характеристики объектов или областей изображения будут извлекаться. Эти признаки могут варьироваться от текстурных особенностей и цветовых характеристик до формы и размера объектов.
2. Преобразование данных. После выбора признаков, они могут быть извлечены из изображения или других данных путем применения различных алгоритмов и методов обработки сигналов.
3. Представление признаков. Полученные признаки представляются в форме векторов или наборов чисел, которые могут быть использованы в алгоритмах машинного обучения для обучения моделей и принятия решений.

Хорошо подобранные признаки могут значительно повысить производительность алгоритмов и моделей, делая их более способными к распознаванию и классификации объектов.

**Классификация объектов** — это процесс присвоения объекту (например, изображению, тексту, звуку или другим данным) определенной категории или класса на основе его характеристик и свойств. Это одна из ключевых задач в области машинного обучения и компьютерного зрения. Процесс классификации объектов обычно включает в себя следующие шаги:

1. Подготовка данных. Исходные данные, например, изображения или текст, подготавливаются для использования в алгоритме классификации. Это может включать в себя масштабирование, нормализацию, преобразование данных и другие этапы предварительной обработки.
2. Извлечение признаков. Из данных извлекаются характеристики, которые будут использоваться для классификации. Это может включать в себя извлечение цветовых характеристик, текстур, формы, числовых значений и т.д., в зависимости от типа данных.

3. Выбор модели. Выбирается модель машинного обучения, которая будет использоваться для классификации. Это может быть, например, модель логистической регрессии, метод k-ближайших соседей, метод опорных векторов (SVM), нейронные сети и так далее.
4. Обучение модели. Процесс обучения модели включает в себя использование предварительно размеченных данных. Этот этап предполагает передачу модели входных данных и соответствующих им меток классов для того, чтобы модель могла усвоить связи между входными признаками и классами.
5. Тестирование и оценка. Обученная модель тестируется на новых данных, которые она ранее не видела, чтобы оценить ее производительность и точность. Различные метрики, такие как точность, полнота, F-мера, могут использоваться для оценки качества классификации.
6. Применение. После успешного обучения и тестирования, модель может быть использована для классификации новых данных.

Задачи классификации объектов имеют широкий спектр применений и играют важную роль в автоматизации и обработке данных. При этом возможны два подхода – на основе обучения с учителем или на основе обучения без учителя.

При обучении с учителем (Supervised Learning) модель обучается на основе размеченных данных, где для каждого входного примера предоставляется соответствующая метка или целевое значение. При этом модель стремится найти отображение между входными данными и соответствующими целевыми метками, чтобы затем, когда она сталкивается с новыми, ранее не виденными данными, способна предсказать или классифицировать целевые метки. Наиболее часто используются следующие методы построения моделей [91]:

1. Линейная регрессия — используется для предсказания непрерывной зависимой переменной на основе одной или нескольких независимых переменных. Основная идея заключается в том, чтобы найти линейную зависимость между признаками и целевой переменной, которая может быть выражена в виде уравнения прямой линии или гиперплоскости в

пространстве большей размерности. Процесс обучения модели заключается в настройке параметров модели на основе обучающих данных с целью минимизации ошибки предсказания. После обучения модель может использоваться для прогнозирования значений целевой переменной для новых наблюдений на основе значений признаков. Качество модели линейной регрессии обычно оценивается с помощью различных метрик, таких как среднеквадратичная ошибка (MSE), коэффициент детерминации ( $R^2$ ), средняя абсолютная ошибка (MAE) и другие.

2. Методы опорных векторов (SVM) — выполняют задачи классификации и регрессии путем разбиения пространства признаков с помощью гиперплоскостей. Основная идея метода SVM заключается в поиске наилучшей гиперплоскости, которая наилучшим образом разделяет различные классы данных в пространстве признаков. Гиперплоскость является такой разделяющей поверхностью, которая максимизирует расстояние (зазор) между ближайшими точками разных классов, называемыми опорными векторами. Параметры гиперплоскости ищутся исходя из минимизации функционала потерь с учетом штрафа за нарушение границы разделения. SVM может использовать различные ядра, которые позволяют строить нелинейные разделяющие поверхности в исходном пространстве признаков путем преобразования данных в пространство более высокой размерности. При классификации спутниковых снимков данный метод может применяться для отнесения пикселей изображения к тому или иному классу, т.е. в задачах сегментации [92].
3. Деревья решений и случайный лес. Алгоритм строит деревья решений для классификации и регрессии, а также их комбинации в случайные леса для повышения точности. Основная идея решающих деревьев заключается в разбиении пространства признаков на регионы, в каждом из которых модель делает прогнозы о целевой переменной. Случайный лес создает ансамбль решающих деревьев, каждое из которых обучается на подмножестве обучающих данных и с использованием случайно выбранных признаков. В

случайном лесе используется две формы случайности: случайное выборка наблюдений с заменой (bootstrap) и случайный выбор признаков на каждом разбиении дерева. Это помогает снизить корреляцию между деревьями и уменьшить переобучение. Когда необходимо сделать прогноз для нового наблюдения, каждое дерево в случайном лесе делает свой собственный прогноз, а затем прогнозы агрегируются (например, с помощью голосования для классификации или усреднения для регрессии) для получения окончательного решения. Случайный лес также может использоваться для сегментации спутниковых снимков.

4. Нейронные сети – это модели, которые могут обучаться предсказывать или классифицировать данные с использованием слоев нейронов и алгоритмов обратного распространения ошибки. Нейронные сети состоят из нейронов, которые группируются в слои. Обычно нейронные сети имеют три типа слоев: входной слой, скрытые слои и выходной слой. Каждый нейрон в одном слое связан с нейронами в следующем слое. Эти связи имеют веса, которые подстраиваются в процессе обучения для достижения оптимальной работы сети. Обычно это происходит с использованием методов оптимизации, таких как стохастический градиентный спуск. На каждом нейроне применяется функция активации, которая определяет выходное значение нейрона на основе входных данных и весов связей. Метод глубокого обучения использует нейронные сети с несколькими скрытыми слоями. Такие сети называют глубокими нейронными сетями. В зависимости от решаемых задач используются различные архитектуры нейронных сетей - многослойные перцептроны (MLP), сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN) и глубокие нейронные сети (DNN). При обработке спутниковых снимков, как правило применяются глубокие сверточные нейронные сети [93].

При обучении без учителя (Unsupervised Learning) модель обучается на неразмеченных данных, и целевые метки отсутствуют. Модель вынуждена

самостоятельно находить структуры или паттерны в данных. Таким образом модель стремится выделить общие характеристики или структуры в данных, а также может использоваться для уменьшения размерности данных. Для обработки спутниковых снимков наиболее успешно используются методы кластеризации. При этом хорошие результаты показывает алгоритм k-средних. Он применяется как для предварительной сегментации всего изображения с целью выявления различных областей интереса, так и для сегментации самих областей интереса, например, для определения степени развития сельскохозяйственных растений на полях [94].

Методы кластеризация представляют собой алгоритмы, которые группируют данные на основе их сходства. Алгоритм k-средних это метод кластеризации, который используется для разделения набора данных на k кластеров. Основная идея заключается в том, чтобы разделить данные на кластеры таким образом, чтобы объекты внутри одного кластера были более похожи друг на друга, чем на объекты из других кластеров. Количество кластеров задается пользователем. Сначала выбираются тем или иным образом центры для каждого кластера. Затем каждый объект данных присваивается к ближайшему центроиду, создавая таким образом кластеры. После присвоения объектов к кластерам, центроиды образованных кластеров пересчитываются путем вычисления среднего значения всех объектов в каждом кластере. Процесс присвоения кластеров и пересчета центроидов повторяется до тех пор, пока центроиды не стабилизируются или пока не будет достигнуто максимальное количество итераций. Для оценки качества кластеризации могут использоваться различные метрики, такие как сумма квадратов расстояний до центроидов, расстояние между центроидами или их отношение этих метрик.

Анализ объектов и классификация изображений повышают точность и контекстуальное понимание анализируемых данных, что делает их более полезными для широкого круга задач в различных областях. Сегментация и классификация больших данных возможна на основе применения нейронных сетей и оптимизации их гиперпараметров. Практически все современные системы

обработки спутниковых изображений основаны на применении нейронных сетей глубокого обучения, поскольку они позволяют добиваться высокой точности сегментации и классификации объектов [94].

## 2.5. Глубокие нейронные сети

Глубокое обучение опирается на применении многослойных нейронных сетей для получения высокоуровневых признаков из входных данных. На каждом слое таких сетей, в результате обучения, формируются свой специфический набор признаков, отражающий как локальные особенности, так и общие признаки обрабатываемых данных [95]. Архитектуры семантической сегментации, основанные на сверточных нейронных сетях, могут специфически извлекать контекстуальные особенности и информацию уровня объекта на нескольких уровнях и, наконец, маркировать каждый пиксель входного изображения [96]. Они применяются во многих задачах анализа изображений, включая обработку спутниковых снимков, медицинские исследования, робототехнику, автономные транспортные средства, точное земледелие и т.д. [96,97]. В области дистанционного зондирования многие исследования применяли алгоритмы семантической сегментации к 2D-изображениям и даже 3D-сценам [98]. Например, модель полностью сверточных сетей была применена к данным Sentinel-2 и SAR для картирования трещин с передачей обучения на основе оптических спутниковых изображений очень высокого разрешения (VHR) [99]. CloudNet, модель семантической сегментации изображений с глубоким остаточным обучением и атрофической сверткой, была предложена для идентификации облаков и дымки на изображениях Sentinel-2 [100]. Сеть DeepUNet, являющаяся переработанной сетевой структурой U-Net, использовалась для сегментации морей и суши на уровне пикселей с помощью вручную размеченных аннотаций и изображений из Google Earth [101]. Таким образом, модели на основе DL открывают новые

возможности для обнаружения объектов, особенно в случаях, когда используются изображения дистанционного зондирования высокого и среднего разрешения.

Конволюционные нейронные сети (CNN) — это класс нейронных сетей, специализирующихся на обработке структурированных данных (например, изображений) в виде решеток или матриц для задач компьютерного зрения, таких как классификация изображений, обнаружение объектов и сегментация изображений. Они успешно применяются. Основные компоненты конволюционных нейронных сетей включают:

1. Сверточные слои, которые применяют фильтры (ядра свертки) к изображению для извлечения различных признаков. Эти слои позволяют сети автоматически изучать важные характеристики изображения, такие как грани, текстуры и формы. На каждом слое формируются так называемые «карты признаков», которые обрабатываются другими фильтрами на последующем слое сети.
2. Пулинг слои - уменьшают размерность признакового пространства, удаляя избыточные данные и упрощая вычисления.
3. Полносвязные слои используются для классификации или регрессии на основе извлеченных признаков. Существуют также сети, в которых полносвязные слои отсутствуют и заменяются на сверточные слои.
4. Функции активации - применяются после каждого слоя для добавления нелинейности в сеть. Наиболее часто между слоями используется функция активации ReLU (Rectified Linear Unit), а на выходном слое как правило используется сигмоидальная функция активации.

При обучении сети минимизируется функция потерь. Эта функция оценивает тем или иным образом разницу между прогнозами сети и истинными метками. Функция потерь строится в зависимости от характера решаемой задачи. Наиболее часто используются следующие функции потерь: среднеквадратическая ошибка (MSE) и кросс-энтропийная функция. В задачах сегментации функцию потерь формируют на основе коэффициента Жаккара или метрики IoU [102].

Поскольку при обучении решается оптимизационная задача, то могут быть использованы различные алгоритмы оптимизации. Эти алгоритмы обновляют параметры сети в процессе обучения для минимизации функции потерь. Как правило применяют алгоритмы на базе стохастического градиентного спуска, такие как оптимизатор Адама [102].

Еще один метод, который можно использовать для ускорения и нормализации процесса обучения нейронных сетей, — пакетная нормализация (Batch Normalization). Этот метод нормализации активаций в нейронных сетях, который был предложен в 2015 году. Он используется для стабилизации и ускорения обучения глубоких нейронных сетей путем нормализации входных данных каждого слоя. Основная идея заключается в том, чтобы нормализовать активации каждого слоя перед их передачей на следующий слой. Это помогает предотвратить взрывной рост градиентов и ускоряет сходимость обучения. Основные компоненты Batch Normalization включают в себя:

1. Вычисление статистик пакета (Batch Statistics). Для каждого мини-пакета данных вычисляются среднее и стандартное отклонение активаций.
2. Нормализация активаций. Активации каждого слоя нормализуются путем вычитания среднего и деления на стандартное отклонение, затем применяется масштабирование с помощью масштабирующего параметра и добавление смещения с помощью параметра смещения.
3. Обновление параметров. Параметры масштабирования и смещения обучаются вместе с остальными параметрами сети в процессе обратного распространения ошибки.

Batch Normalization часто применяется к результатам операции свертки в сверточных слоях или к результатам работы полносвязного слоя в нейронных сетях. Он помогает ускорить обучение, улучшить стабильность обучения и обычно приводит к лучшей обобщающей способности моделей [102].

После нормализации процесса обучения необходимо избегать процесса переобучения, для этого используется метод регуляризации. Это еще один метод в

машинном обучении, который используется для предотвращения переобучения модели путем ограничения ее сложности или размера весов. Основная идея регуляризации заключается в добавлении дополнительного члена к функции потерь модели, который штрафует большие значения весов или их сложность. Существует два основных типа регуляризации [102]:

1. L1 регуляризация (Lasso). В этом методе добавляется штраф к функции потерь, пропорциональный абсолютной величине весов модели. L1 регуляризация также называется методом Lasso (Least Absolute Shrinkage and Selection Operator). Она может приводить к разреженным весам, поскольку она может обнулять некоторые веса, делая модель более интерпретируемой.
2. L2 регуляризация (Ridge). В этом методе добавляется квадратичный штраф к функции потерь, пропорциональный квадрату весов модели. L2 регуляризация также называется методом Ridge или Tikhonov регуляризации. Она стремится сделать веса модели меньше и предотвратить их переобучение.

Регуляризация часто используется вместе с другими методами машинного обучения, такими как линейная регрессия, логистическая регрессия или нейронные сети. Она помогает улучшить обобщающую способность моделей и предотвратить их переобучение на обучающих данных [102].

К методам глубокого обучения относится также так называемый перенос обучения (Transfer Learning). Это метод машинного обучения, который позволяет использовать знания, полученные при обучении модели на одной задаче, для улучшения производительности или ускорения обучения модели на другой задаче. Основная идея заключается в том, чтобы использовать предварительно обученные веса модели, обученной на большом наборе данных, и настроить их на новом наборе данных, связанном с новой задачей. Ключевые аспекты Transfer Learning:

- Предварительное обучение. Сначала модель обучается на большом наборе данных и получает знания о признаках и зависимостях в данных.

- Перенос знаний. После этого знания, полученные в ходе предварительного обучения, передаются или переносятся на новую задачу. Это может включать использование предварительно обученных весов нейронной сети или функций извлечения признаков.
- Настройка модели. Затем модель настраивается или дообучается на новом наборе данных для выполнения конкретной задачи. Это может включать изменение последних слоев модели или использование техники обучения с замороженными слоями.

Transfer Learning позволяет использовать знания, полученные на одной задаче, для улучшения производительности модели на другой задаче, особенно если доступно небольшое количество обучающих данных для новой задачи. Этот метод позволяет значительно снизить затраты на обучение новых моделей и улучшить производительность моделей на новых задачах, особенно в условиях ограниченного количества доступных данных.

### 2.5.1. Архитектуры кодер – декодер

Архитектуры кодер-декодер (encoder-decoder) — это класс нейронных сетей, который состоит из двух основных компонентов - кодера и декодера. Эти архитектуры широко применяются в различных областях машинного обучения, таких как машинный перевод, генерация текста, сегментация изображений и другие [103].

#### **Кодер (Encoder):**

- Кодер принимает на вход данные и преобразует их в некоторое скрытое представление или код.
- Обычно кодер состоит из нескольких слоев нейронных сетей, которые постепенно снижают размерность входных данных и извлекают их признаки.

- Для обработки последовательных данных, таких как текст или временные ряды, в кодере могут использоваться рекуррентные нейронные сети (RNN), сверточные нейронные сети (CNN) или их комбинации.

### **Декодер (Decoder):**

- Декодер принимает скрытое представление, полученное от кодера, и декодирует его обратно в выходные данные.
- Декодер также состоит из нескольких слоев нейронных сетей, которые постепенно увеличивают размерность данных до оригинальной размерности входных данных.
- Он также может использовать рекуррентные слои для моделирования зависимостей между входными и выходными данными, особенно в случае генерации последовательностей.

### **Механизм внимания (Attention Mechanism):**

- В некоторых архитектурах кодер-декодер добавляется механизм внимания, который позволяет сети фокусироваться на различных частях входных данных в разное время.
- Это помогает улучшить качество вывода, особенно в задачах, где необходимо обрабатывать длинные последовательности или входы переменной длины.

Архитектуры кодер-декодер используются для решения самых различных задач – как для сегментации изображений, так и для машинного перевода, а также генерации текста. Эти архитектуры обладают высокой гибкостью и могут быть адаптированы для различных задач и типов данных. К числу наиболее успешных архитектур, обеспечивающих относительно высокие оценки качества в разных задачах, относятся следующие:

1. Модели Seq2Seq (Sequence-to-Sequence) применяются в задачах машинного перевода, вопрос-ответ, генерации текста и других задачах, где необходимо преобразовать одну последовательность в другую.

2. Модели для генерации текста, которые основаны на рекуррентных элементах, таких как LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit), которые преобразуют скрытые представления последовательности в текст.
3. Архитектуры SegNet и U-Net, которые показали хорошие метрики качества в задаче сегментации изображений, где входные изображения преобразуются в сегментированные маски.

### **2.5.2. Архитектуры нейронных сетей для сегментации изображений**

Семантическая сегментация изображений — это выделение локальных областей изображения, соответствующих различным классам объектов. Хотя методы и алгоритмы классификации объектов на изображениях быстро развиваются, эта проблема до сих пор не решена полностью. С другой стороны, не существует единого общепринятого подхода, который мог бы лечь в основу большинства алгоритмов. Также не существует общего алгоритма, который обеспечивал бы наилучшую сегментацию для любого изображения.

В настоящее время существует множество методов семантической сегментации изображений, основанных на применении сверточных нейронных сетей (CNN). В целом такие методы обеспечивают достаточно хорошую производительность и точность сегментации относительно небольших изображений. При этом различные архитектуры CNN используются для классификации и плотной маркировки этих изображений. Однако эти нейросетевые методы обработки изображений имеют определенные недостатки и далеки от совершенства. Следует также отметить, что вычислительные затраты на сегментацию высоки из-за высокого разрешения спутниковых снимков земной поверхности. Поэтому очень важно разработать методы, позволяющие снизить вычислительные затраты и повысить качество сегментации.

В настоящее время нет строгих правил для конфигурации структур сверточных нейронных сетей (CNN) — это включает в себя выбор количества слоев, размеров и количества карт признаков, а также размеры матриц свертки, алгоритмы обучения и т. д. При разработке структур CNN важно учитывать, что небольшое количество параметров сети может снизить точность классификации. В то же время большое количество параметров может повысить вычислительную сложность и не всегда приводит к улучшению классификационной способности сети.

Семантическая сегментация в компьютерном зрении заключается в назначении семантической метки каждой связанной области изображения. Почти все современные архитектуры CNN для сегментации изображений следуют принципам, изложенным в [104]. Основная идея состоит в том, чтобы изменить традиционную классификацию CNN таким образом, чтобы на выходе был не вектор вероятности, а карта вероятности классов. Как правило, стандартная CNN используется в качестве кодировщика, который формирует карты признаков для различных уровней разложения изображения. За кодировщиком следует декодер, который масштабирует карты признаков до исходных пространственных размеров входного изображения. Затем для каждого класса получается тепловая карта. Глубокие сети семантической сегментации, обычно основаны на принципах полной свертки и архитектурах кодер – декодер [124].

Как правило кодер представляет собой последовательность сверточных слоев с последующей пакетной нормализацией (BN) и выпрямленной линейной функцией активации (ReLU). За блоками свертки следует слой пуллинга. Фактически кодер это обычная сверточная сеть, обучаемая для классификации входного изображения. Декодер имеет такое же количество слоев и выполняет функцию интерполяции выхода кодера. На последнем уровне декодера, для формирования выходного сегментированного изображения, как правило, используется свертка  $1 \times 1$  с последующей сигмоидальной функцией активации.

U-Net [105] и MobileNet [106] представляют собой две различные архитектуры нейронных сетей, разработанные для решения разных задач. U-Net

обычно используется для сегментации изображений. Архитектура включает в себя сверточные слои для извлечения признаков и транспонированные сверточные слои для увеличения размерности и создания детализированных сегментированных карт.

В архитектуре Unet при использовании операции пулинга применяется метод максимизации по области пикселей размером  $2 \times 2$ . После прохождения через несколько последовательных слоев свертки и пулинга, входное изображение преобразуется в абстрактные карты признаков, которые являются выходными данными соответствующих блоков кодирования.

Сеть Unet можно рассматривать как модифицированную версию кодера - декодера, в которой объединяются выходные данные слоев декодера с картами признаков из кодера на том же уровне. При этом интерполяция в слоях декодера производится с помощью транспонированной свертки [107]. Данная архитектура показала существенное повышение точности сегментации изображений различной природы, а также возможность обучаться на небольшом объеме данных. Недостатками Unet, является относительно низкая производительность и большая ресурсоемкость. Эти недостатки связаны с достаточно сложными и ресурсоемкими архитектурами, применяемых кодировщиков, таких как ResNet [108], Inception [109], EfficientNet [110].

MobileNet, с другой стороны, разработан для классификации изображений с минимальным количеством параметров. Его легковесная архитектура делает его подходящим для работы на мобильных устройствах и встраиваемых системах. Благодаря своей легкой архитектуре MobileNet позволяет быстро обрабатывать изображения и извлекать важные функции. MobileNet заменяет стандартные сверточные слои в кодировщике на глубинные свертки. Это уменьшает количество параметров и расчетов, что полезно для ресурсоемких сценариев. MobileNet можно использовать в качестве кодировщика в архитектуре U-Net, когда необходима высокая производительность в средах с ограниченными ресурсами.

Первоначально архитектура нейронной сети U-Net, была разработана для семантической сегментации медицинских изображений. С ее помощью на

изображениях, получаемых с микроскопов, выделялись определенные типы клеток. Эта же архитектура использовалась для сегментации аномалий органов на томографических изображениях. Однако затем эту архитектуру начали успешно применять и для сегментации других изображений, в том числе спутниковых снимков. Основная идея U-Net заключается в использовании полностью сверточной архитектуры, которая одинаково хорошо работает как для кодирования (уменьшения размерности) изображения, так и для декодирования (увеличения размерности) полученного представления с целью восстановления сегментированных картинок. Основные черты архитектуры U-Net включают в себя [105]:

1. Сверточные блоки. Архитектура состоит из последовательности сверточных блоков, включающих свертку, функцию активации (обычно ReLU) и операцию пулинга. Эти блоки используются для извлечения признаков из входного изображения.
2. Путь кодировщика (Encoder Path). Входное изображение последовательно уменьшается в размере с помощью операций свертки и пулинга, что позволяет извлекать все более абстрактные признаки.
3. Путь декодировщика (Decoder Path). После достижения минимального размера изображения, размер постепенно увеличивается с помощью операций транспонированной свертки и конкатенации с выходами блоков кодировщика, что позволяет восстанавливать пространственное разрешение и производить сегментацию.
4. Остаточные соединения (Skip Connections). Для улучшения передачи информации между кодировщиком и декодером, используются пропускающие соединения, которые передают признаки с более низких уровней напрямую на соответствующие слои декодера.
5. Функция потерь. Обычно в качестве функции потерь используется перекрестная энтропия (cross-entropy loss), особенно для задачи бинарной сегментации, или среднеквадратичная ошибка (mean squared error) для задачи сегментации с несколькими классами.

U-Net демонстрирует высокую эффективность в решении задач сегментации изображений благодаря своей специальной архитектуре, которая позволяет извлекать как локальные, так и глобальные признаки из изображений, сохраняя при этом пространственную информацию и детали. Однако эта архитектура весьма ресурсоёмка. Она требует, как больших объемов памяти, так и мощных графических ускорителей, даже при обработке изображений среднего разрешения.

В данной работе для семантической сегментации спутниковых снимков предлагается использовать нейронную сеть, построенную на принципах архитектуры U-Net. При этом основное внимание будет обращено на снижение требований к необходимым вычислительным ресурсам, при этом точность сегментации не должна уменьшаться. Предлагаемый метод рассматривается далее в третьей главе работы.

## Выводы к главе 2

1. Для атмосферной коррекции предлагается использовать нейронную сеть. Это связано с тем, данные (изображения), полученные из хабов доступа к данным, как правило, предоставляются с произведенной атмосферной коррекцией. Однако часто имеющиеся данные не всегда имеют атмосферную коррекцию. Поэтому предлагается метод позволяющий автоматизировать процесс атмосферной коррекции «сырых» спутниковых изображений при помощи простой сверточной нейронной сети, реализующей архитектуру кодер - декодер. На вход такой сети поступают изображения без атмосферной коррекции, а результатом ее работы будут изображения с атмосферной коррекцией. Сеть должна обучаться на датасете, сформированном из изображений земной поверхности с уже осуществленной атмосферной коррекцией и изображений тех же районов без неё. Такой подход позволит провести атмосферную коррекцию и для тех спутниковых данных, для которых отсутствует атмосферная коррекция.
2. Для классификации выращиваемых культур на землях сельскохозяйственного назначения предлагается использовать набор различных вегетационных индексов. Это обусловлено тем, что указанные индексы различаются для различных культур, а также отражают степень развития растительности. Таким образом вегетационные индексы можно использовать в дальнейшем, как информативные признаки для системы распознавания типов сельскохозяйственных культур. Кроме того, вегетационные индексы можно использовать для предварительного выявления земель сельскохозяйственного назначения.
3. Для решения задач атмосферной коррекции, сегментации спутниковых снимков и классификации сельскохозяйственных культур предлагается использовать нейронные сети на основе различных архитектур. Это обусловлено хорошим показателями по точности, достигаемые с их

помощью. Следует отметить, что при их реализации необходимо снизить требования к вычислительным ресурсам, но при этом точность результатов, по крайней мере, не должна уменьшаться по сравнению с уже существующими решениями.

## ГЛАВА 3. РАЗРАБОТКА МЕТОДОВ МОНИТОРИНГА ТЕРРИТОРИИ НА ОСНОВЕ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ

### 3.1. Общая структура системы мониторинга районов земной поверхности

На основе анализа, проведенного в главе 2, предлагается следующая структура системы обработки спутниковых данных для мониторинга региона земной поверхности, показанная на Рисунк 3.1.

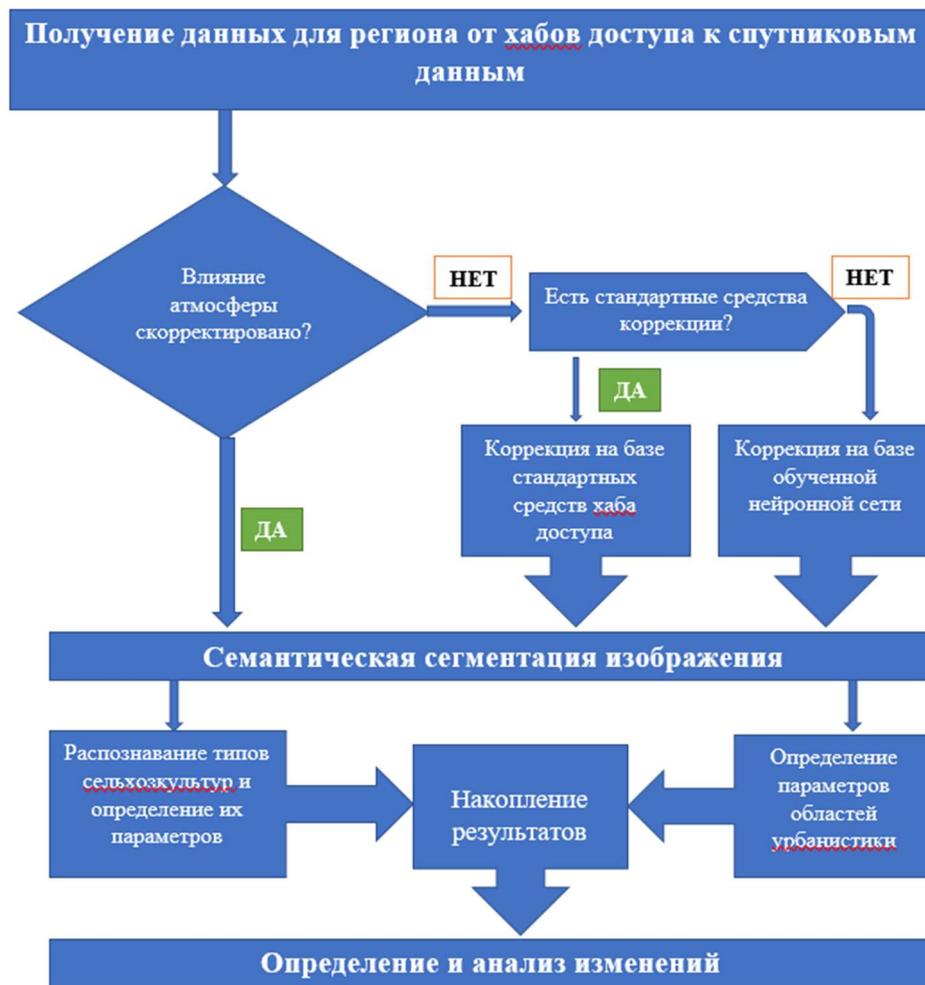


Рисунок 3.1. Структура системы мониторинга региона земной поверхности

В рамках предлагаемой структуры отражены основные составляющие системы мониторинга – получение данных с использованием двух методов

атмосферной коррекции, а также компоненты, реализующие сегментацию и классификацию сегментированных областей, и дальнейший их анализ [123].

### 3.2. Мониторируемые регионы

Для оценки различных методов обнаружения изменений, представленных в данной диссертации, в качестве мест для исследования были выбраны города Узбекистана в Ферганской долине. Как крупнейшие города Узбекистана, Ташкент, Фергана, Андижан и Наманган испытали быстрые изменения в своей городской структуре. Такая высокая скорость расширения делает их привлекательными кандидатами для исследования обнаружения изменений в городах с использованием изображений дистанционного зондирования.

Ташкент – один из центров Центральной Азии, столица суверенной Республики Узбекистан. Ташкент расположен в северо-восточной части республики, в зоне наблюдения в долине реки Чирчик, на высоте 440—480 метров над уровнем моря и занимает около 43 500 гектаров.

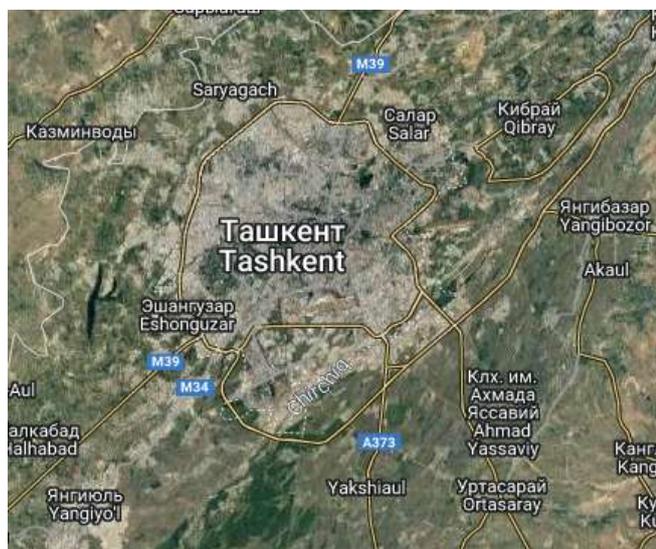


Рисунок 3.2. Город Ташкент, снятый спутником Landsat (платформа Google Earth Engine)

Город Фергана, расположенный на юге Ферганской долины, — один из самых молодых городов Узбекистана. Создан в 1876 году в результате



### 3.3. Методы получения спутниковых данных

Прежде чем выбрать источник данных для региональной системы мониторинга, важно учесть такие факторы, как доступность данных, стоимость, качество и совместимость с существующими инструментами и программным обеспечением. В данном исследовании данные получены из двух основных источников: Google Earth Engine и платформы Sentinel Hub.

#### 3.3.1. Получение данных с Google Earth Engine в интерактивном режиме

Google Earth Engine (GEE) предлагает широкий спектр наборов данных и инструментов, которые могут предоставить различные типы информации для мониторинга территории Узбекистана. Чтобы получить информацию от Google Earth Engine, необходимо зарегистрироваться и войти на платформу, выбрать область интересов (AOI) для Узбекистана, выполнить поиск соответствующих наборов данных и обработать данные с помощью функций обработки изображений GEE. Чтобы получить информацию от GEE для мониторинга территории Узбекистана, могут последовать некоторые шаги:

1. Необходимо зарегистрироваться и войти на платформу Google Earth Engine с помощью учетной записи Google.

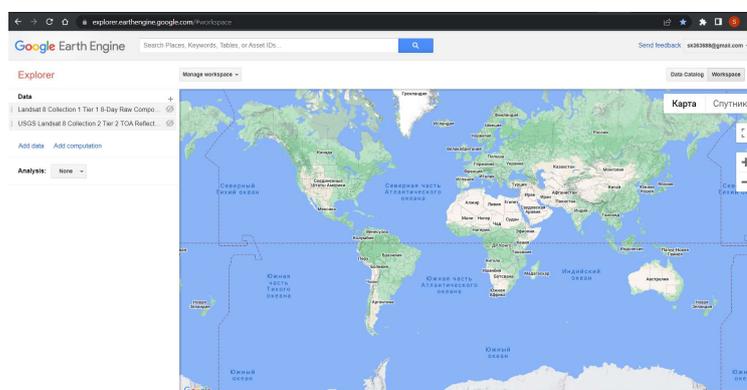


Рисунок 3.5. Рабочая область платформы Google Earth Engine

2. Необходимо выбрать зону интереса для Узбекистана. Это можно сделать, нарисовав многоугольник над нужной областью, используя инструмент «Нарисовать фигуру» в пользовательском интерфейсе GEE.
3. После этого следует выполнить поиск наборов данных, содержащих релевантные данные для выбранной области интереса. Это можно сделать, используя вкладку «Поиск» в пользовательском интерфейсе GEE и фильтруя, по ключевым словам, типу данных и другим критериям.

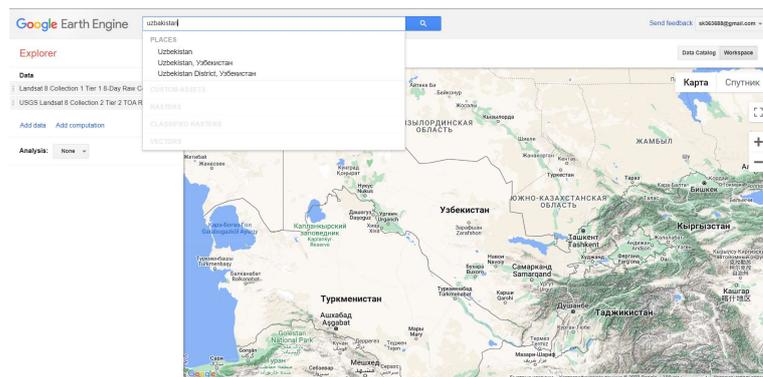


Рисунок 3.6. На платформе область научных исследований можно найти через поисковика или через графический помощник

4. Нужно выбрать нужные наборы данных и добавить их в рабочую область GEE. Это можно сделать, нажав на набор данных, а затем нажав «Добавить на карту».
5. Обработать данные с помощью функций обработки изображений GEE. Это можно сделать, написав код JavaScript и Python на вкладке «Редактор кода» в пользовательском интерфейсе GEE. Код можно использовать для фильтрации, обработки и визуализации данных.
6. В завершение следует экспортировать обработанные данные для дальнейшего анализа. Это можно сделать, используя вкладку «Экспорт» в пользовательском интерфейсе GEE и выбрав нужный формат экспорта и параметры.

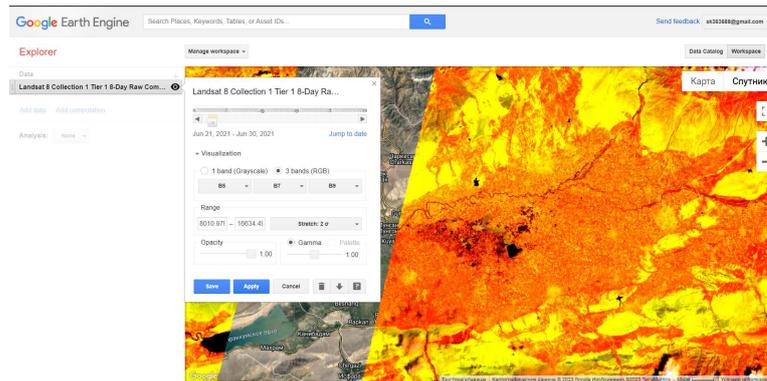


Рисунок 3.7. Некоторые настройки можно произвести на объекте исследования на платформе. Например, спектральные диапазоны и служба автокоррекции

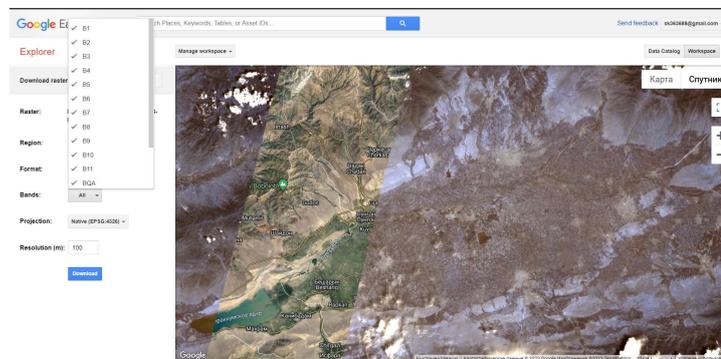


Рисунок 3.8. Есть возможность заранее настроить и скачать необходимые спутниковые данные с платформы

### 3.3.2. Получение данных с Google Earth Engine в автоматическом режиме

Автоматизированный сбор данных с Google Earth Engine означает использование программных инструментов для извлечения и загрузки геопространственных данных с облачной платформы Google Earth Engine без ручного вмешательства. Google Earth Engine предоставляет обширные наборы геопространственных данных и мощные инструменты анализа, доступные через API, которые автоматизируют процесс сбора данных. Google Earth Engine предоставляет широкий спектр геопространственных данных, которые можно использовать для различных приложений, включая анализ сельскохозяйственных угодий, мониторинг изменений растительности, оценку риска стихийных бедствий

и многое другое. В качестве примера анализа данных для Узбекистана рассмотрим подробный алгоритм работы с Google Earth Engine API:

1. Установка и настройка API:

- Надо проверить, что у вас установлена библиотека `earthengine-api` для Python.
- Необходимо зарегистрироваться в Google Earth Engine и создать учетную запись с доступом к API.

2. Импорт библиотеки и инициализация API:

- Импорт библиотеки API Python Earth Engine: `import ee`.
- API необходимо инициализировать с помощью команды `ee.Initialize()`.

3. Определение области интереса (AOI):

- Определите географическую область Узбекистана, используя геометрический объект (например, прямоугольник), задав координаты.

4. Выбор данных:

- Необходимо выбрать данные, которые вы хотите проанализировать. Например, это может быть набор данных Landsat для мониторинга изменений растительности.

5. Фильтрация данных:

- Для выбора информации, относящейся только к Узбекистану, можно применять фильтры по времени и региону.
- Облачные фильтры можно использовать для исключения облачных сцен.

6. Анализ данных:

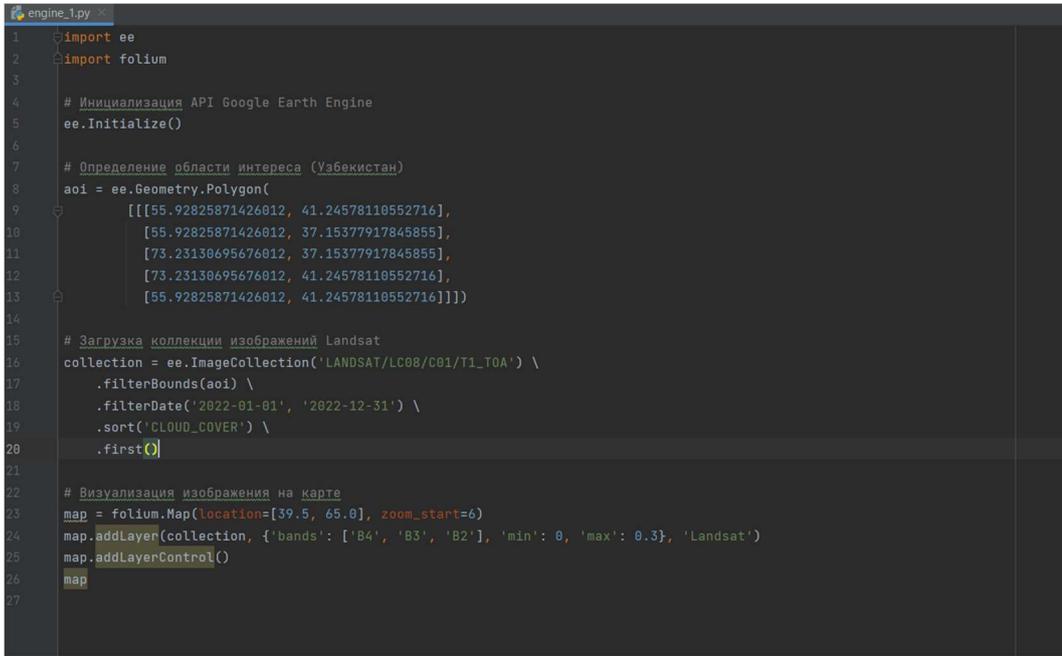
- Могут быть применены такие операции анализа, как расчет индексов растительности (NDVI, NDWI), классификация, динамическое преобразование и т. д.

7. Визуализация результатов:

- Визуализация результатов, например, с использованием графиков или карт.

## 8. Экспорт данных (опционально):

- При необходимости данные можно экспортировать в нужный формат для дальнейшего использования в других приложениях.



```

1 import ee
2 import folium
3
4 # Инициализация API Google Earth Engine
5 ee.Initialize()
6
7 # Определение области интереса (Узбекистан)
8 aoi = ee.Geometry.Polygon(
9     [[55.92825871426012, 41.24578110552716],
10      [55.92825871426012, 37.15377917845855],
11      [73.23130695676012, 37.15377917845855],
12      [73.23130695676012, 41.24578110552716],
13      [55.92825871426012, 41.24578110552716]])
14
15 # Загрузка коллекции изображений Landsat
16 collection = ee.ImageCollection('LANDSAT/LC08/C01/T1_TOA') \
17     .filterBounds(aoi) \
18     .filterDate('2022-01-01', '2022-12-31') \
19     .sort('CLOUD_COVER') \
20     .first()
21
22 # Визуализация изображения на карте
23 map = folium.Map(location=[39.5, 65.0], zoom_start=6)
24 map.addLayer(collection, {'bands': ['B4', 'B3', 'B2'], 'min': 0, 'max': 0.3}, 'Landsat')
25 map.addLayerControl()
26 map
27

```

Рисунок 3.9. Пример кода Python для загрузки и визуализации данных Landsat для Узбекистана с использованием API Google Earth Engine

Это пример загрузки и визуализации изображения Landsat для Узбекистана с использованием API Google Earth Engine. Параметры пакета, фильтры и другие параметры можно настроить в соответствии с потребностями.

### 3.3.3. Получение данных с Sentinel Hub в интерактивном режиме

Sentinel Hub — это облачная платформа, которая обеспечивает доступ к широкому спектру спутниковых данных, включая Sentinel-1, Sentinel-2, Sentinel-3 и другие миссии. Платформа предлагает различные инструменты для визуализации, обработки и анализа данных, что делает ее полезным инструментом для наблюдения за окружающей средой и природными ресурсами. Для получения

информации от Sentinel Hub для Узбекистана необходимо выполнить следующие действия:

1. Следует зарегистрироваться и войти на платформу Sentinel Hub с использованием действительной учетной записи.

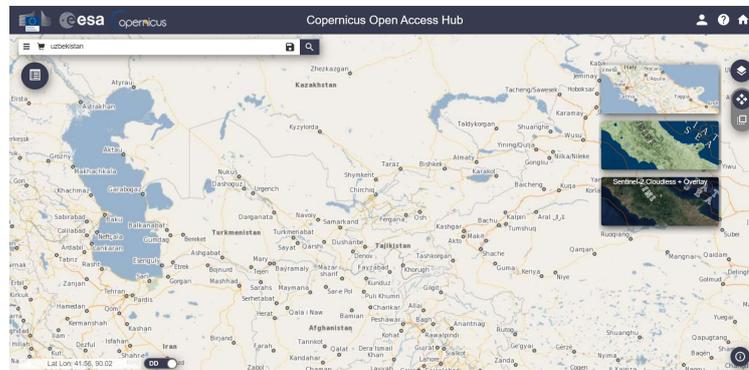


Рисунок 3.10. После регистрации открывается рабочее пространство Sentinel Hub

2. Можно выбрать интересующую область (AOI) для Узбекистана. Это можно сделать, указав координаты широты и долготы нужной области или нарисовав многоугольник, используя интерфейс карты платформы.
3. Необходимо выполнить поиск доступных данных для выбранной области интереса. Это можно сделать с помощью инструментов обнаружения данных платформы, которые позволяют вам фильтровать наборы данных на основе диапазона дат, датчика и других параметров.

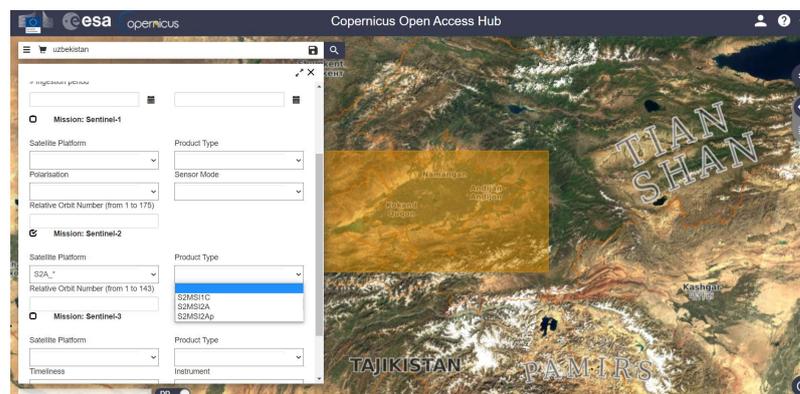


Рисунок 3.11. Выбрав необходимое поле, можно настроить дополнительные фильтры, предлагаемые платформой, и выбрать, с какого спутника можно получить

4. Можно выбрать нужные наборы данных и визуализировать данные, используя инструменты обработки изображений платформы. Этого можно добиться, применяя фильтры, регулируя контрастность изображения и используя другие методы для улучшения визуального представления данных.
5. Необходимо экспортировать данные для дальнейшего анализа. Это можно сделать, загрузив данные в желаемом формате или интегрировав данные с другими программными средствами для анализа и визуализации.

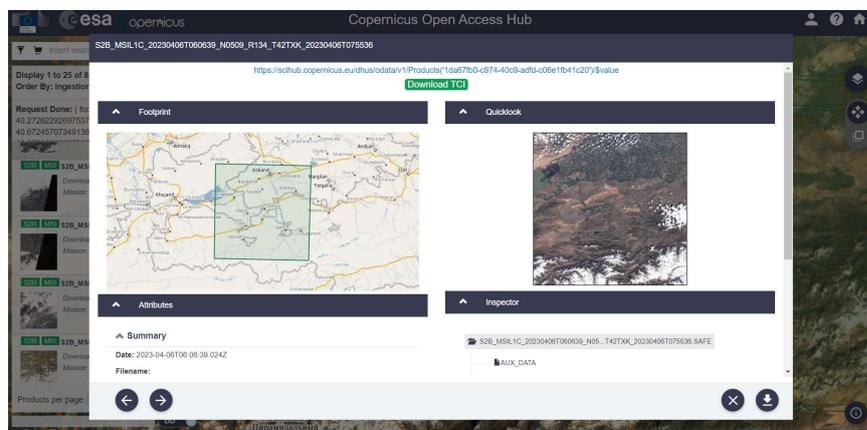


Рисунок 3.12. Перед загрузкой можно еще раз проверить нужную область и скачать ее

### 3.3.4. Получение данных с Sentinel HUB в автоматическом режиме

Для получения данных с Sentinel Hub в автоматическом режиме можно использовать их API, которое предоставляет доступ к широкому спектру геопространственных данных, включая изображения со спутников Sentinel. API (Application Programming Interface) представляет собой интерфейс, который позволяет программному обеспечению взаимодействовать с другими программами или службами. В случае с геопространственными данными, API для работы с Sentinel Hub позволяет разработчикам получать доступ к различным наборам данных о географических объектах, изображениям спутников, метаданным и другой информации через программные запросы.

Пример алгоритма работы с API Sentinel Hub для получения данных о географических объектах и изображений спутников для Узбекистана:

1. Регистрация и получение ключа API:

- Необходимо перейти на веб-сайт Sentinel Hub и зарегистрировать учетную запись.
- Получить ключ API (instance ID), который позволит использовать API Sentinel Hub.

2. Импорт необходимых библиотек:

- Необходимо установить библиотеку Sentinelhub для Python, если она еще не установлена.
- Для работы с API в скрипте Python необходимо импортировать необходимые классы и методы из Sentinelhub.

3. Определение области интереса (AOI):

- Необходимо выбрать географический регион Узбекистана, из которого необходимо получить информацию. Его можно определить, как геометрический объект (например, прямоугольник или многоугольник) с использованием координат.

4. Формирование запроса:

- В API Sentinel Hub отправляется запрос с указанием необходимых параметров, таких как тип данных (например, изображения Sentinel-2), временной интервал, область интереса, размеры изображения и другие параметры.

5. Отправка запроса:

- Подготовленный запрос отправляется в API Sentinel Hub с использованием ключа API и параметров запроса.

6. Получение данных:

- Данные получаются как ответ на запрос. Это могут быть спутниковые снимки, метаданные или другая информация о географических

объектах на определенной территории и в определенный период времени.

#### 7. Обработка и анализ данных:

- Полученные данные обрабатываются и анализируются согласно поставленным целям. Это может включать обработку изображений, извлечение признаков, анализ временных рядов и многое другое.

```
from sentinelhub import SHConfig, BBox, CRS, SentinelHubRequest, DataCollection
import matplotlib.pyplot as plt

# Инициализация конфигурации API
config = SHConfig()
config.instance_id = 'YOUR_INSTANCE_ID' # Замените YOUR_INSTANCE_ID на ваш идентификатор экземпляра

# Определение области интереса (AOI)
bbox = BBox([55.0, 37.0, 73.0, 45.0], CRS.WGS84)

# Формирование запроса к API Sentinel Hub
request = SentinelHubRequest(
    data_folder='./data',
    evalscript='// Оценочный скрипт Sentinel Hub',
    input_data=[
        SentinelHubRequest.input_data(
            data_collection=DataCollection.SENTINEL2_L1C,
            time_interval=('2022-01-01', '2022-01-10'),
            mosaicking_order='leastCC' # Порядок мозаики с наименьшим облачным покрытием
        )
    ],
    bbox=bbox,
    size=(512, 512),
    config=config
)

# Получение данных
response = request.get_data(save_data=True)
```

Рисунок 3.13. Пример кода для получения изображений Sentinel-2 для Узбекистана с использованием API Sentinel Hub

Этот код отправляет запрос к API Sentinel Hub для получения изображений Sentinel-2 для Узбекистана за определенный временной диапазон и визуализирует полученное изображение с помощью библиотеки matplotlib.

### 3.4. Методы предварительной обработки спутниковых изображений

В настоящее время данные с большинства спутников находятся в открытом доступе, но лишь небольшая часть из них представляет собой данные с предшествующей атмосферной коррекцией. Пользователи, имеющие доступ к данным того или иного спутника, могут выполнить атмосферную коррекцию необходимых данных, используя соответствующие прикладные программы. Однако эта обработка выполняется, как правило, интерактивно для каждого изображения определенной области.

Коррекция атмосферных искажений данных, полученных при дистанционном зондировании Земли, является критическим этапом предварительной обработки. Она компенсирует различия между солнечным излучением, отраженным от поверхности, и истинным излучением, зарегистрированным на борту космического аппарата. Эти различия зависят от множества факторов, включая угол падения солнечных лучей, положение и угол обзора космического аппарата, состав и влажность атмосферы, и другие. Часто космические снимки обрабатываются без проведения атмосферной коррекции. Однако внедрение этой коррекции способствует улучшению достоверности результатов обработки спутниковых изображений.

Множество алгоритмов атмосферной коррекции доступны в составе программного обеспечения центров обработки данных для различных семейств спутников. Однако атмосферная коррекция выполняется не для всех данных, полученных с спутников. Пользователи могут проводить собственную предварительную обработку данных, включая атмосферную коррекцию, с использованием специализированных прикладных программ.

Большинство спутников предоставляют мультиспектральные изображения Земли. Данные, получаемые со спутников Sentinel-2 уже частично обработаны на нескольких уровнях. В данной работе применяются два из них, а именно L1C и L2A. Изображения уровня L1C, представляют собой снимки, прошедшие

ортокоррекцию. Изображения, полученные на уровне обработки L2A, прошли как орто, так и атмосферную коррекцию. Пользователи, имеющие доступ только к данным уровня L1C, могут самостоятельно провести атмосферную коррекцию необходимых изображений, используя специализированные приложения, расположенные на хабе доступа Sentinel. Однако такая обработка часто требует интерактивного взаимодействия для каждого изображения в отдельности, что затрудняет автоматическую обработку больших наборов таких изображений. Пример одного и того же изображения в видимом спектральном диапазоне на уровнях L1C и L2A представлен на Рисунке 3.14.

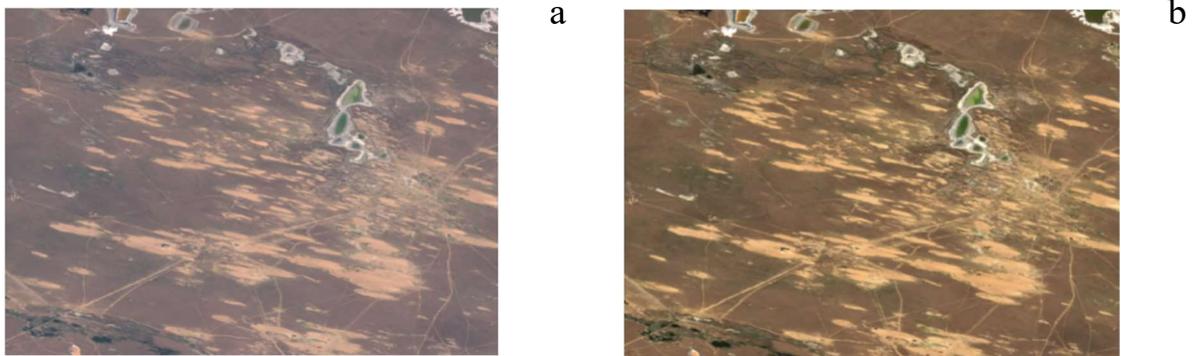


Рисунок 3.14. Снимки на уровнях 1С и 2А: (а) Некорректированное изображение — уровень L1C (б) Снимок с атмосферной коррекцией — уровень L2А

Платформа GEE аккумулирует данные, получаемые от множества спутников, и позволяет при этом выбрать любой из них. Далеко не все, полученные таким образом, данные имеют атмосферную коррекцию. При этом, как правило, средства для проведения атмосферной коррекции для этих данных могут отсутствовать. Поэтому для осуществления атмосферной коррекции данных, полученных из разных источников, предлагается метод, позволяющий произвести данную коррекцию. Метод основан на применении нейронной сети с архитектурой кодер – декодер. В качестве датасета для обучения сети используются имеющиеся данные уровней L1C и L2A, полученные с платформы Sentinel-2.

### 3.4.1. Нейронная сеть для атмосферной коррекции спутниковых изображений

Предлагаемый метод позволяет автоматизировать процесс атмосферной коррекции «сырых» спутниковых изображений при помощи простой сверточной нейронной сети. На вход этой сети поступают изображения без атмосферной коррекции, а результатом ее работы будут изображения с атмосферной коррекцией. Наиболее подходящей архитектурой сети для такого преобразования является архитектура кодер – декодер. Структура предлагаемой нейронной сети показана на Рисунок.3.15а. Кодер содержит только три слоя кодирования. Структура кодирующего слоя приведена на Рисунок. 3.15б. Фактически кодер это обычная сверточная сеть, обучаемая для классификации входного изображения. Декодер имеет такое же количество слоев и выполняет функцию интерполяции выхода кодера. Слой декодирования, показанный на Рисунок. 3.15с, представляет собой обратную свертку с последующей пакетной нормализацией [125].

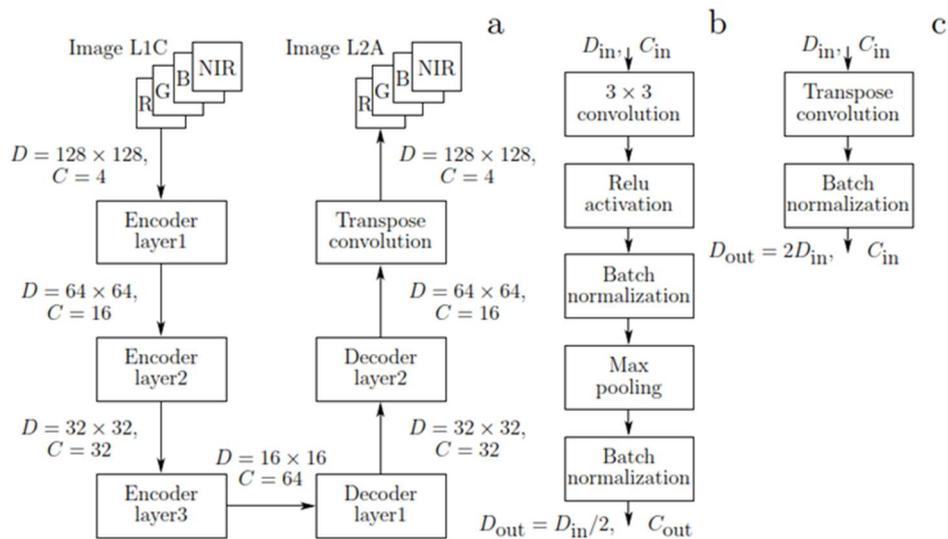


Рисунок 3.15. (а) Структура предлагаемой нейронной сети. (б) Слой кодирования. (с) Слой декодирования.  $D$  обозначает размер изображения,  $C$  — количество фильтров

Исходный набор данных для обучения и тестирования нейронной сети представляет собой подмножество спутниковых изображений из уровней L1C и L2A, полученных для нескольких регионов Земли в разные времена года. Для анализа используются данные, полученные из спектральных каналов B04 (красный), B03 (зеленый) и B02 (синий) в видимом диапазоне, а также данные из канала B08 (ближний инфракрасный) спектрального диапазона. Алгоритм предварительной обработки данных для атмосферной коррекции, показанный на Рисунок 3.16, начинается с выравнивания размеров всех каналов изображений. После этого каждое изображение разбивается на 64 части, и каждая часть нормализуется по яркости. Этот процесс создает 64 четырехканальных изображения. Далее полученный набор изображений случайным образом разделяется на обучающий, проверочный и тестовый наборы данных, составляющие 80%, 10% и 10% от всего набора данных соответственно. Затем проводится обучение сети, которая потом и используется для атмосферной коррекции

На вход обученной нейронной сети подаются корректируемые изображения. Результатом обработки каждого такого изображения являются 64 части выходного изображения. Из этих частей с помощью алгоритма пост обработки, показанного на Рисунок 3.17 komponуется полноразмерное изображение с произведенной атмосферной коррекцией [125].

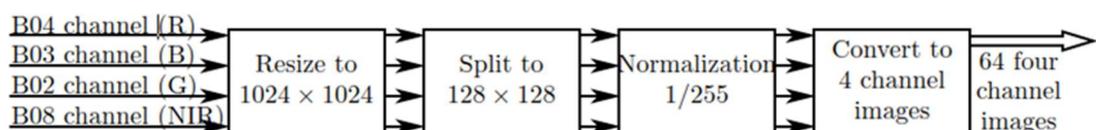


Рисунок 3.16. Алгоритм предварительной обработки данных

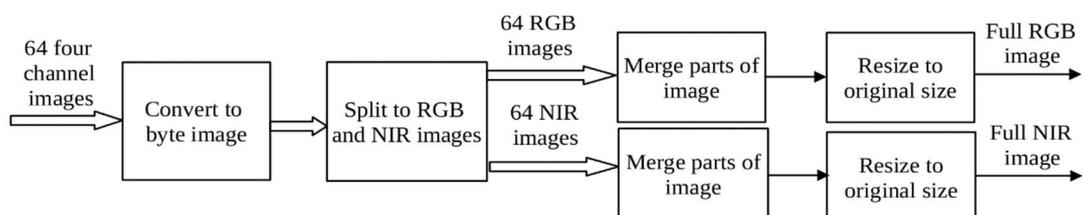


Рисунок 3.17. Алгоритм пост обработки выходных данных

Использование предлагаемой нейронной сети дает возможность провести атмосферную коррекцию и унифицировать изображения, получаемые с разных спутников. Процедура обучения предлагаемой сети и результаты ее использования описаны в главе 4.

### **3.5. Нейронная сеть для семантической сегментации спутниковых изображений**

Как уже отмечалось в главе 2, среди сетей для семантической сегментации, сети, построенные на базе архитектура U-Net, показывают лучшие результаты сегментации по сравнению с другими архитектурами. Поэтому в данной работе и предлагается использовать эту архитектуру в качестве базовой. Однако эта сеть требует для своей работы существенные вычислительные ресурсы, и имеет не слишком высокую производительность, что особенно сказывается при обработке изображений высокого разрешения.

Изображения, полученные при дистанционном зондировании Земли, имеют высокое разрешение, часто превышающее 2000x2000 пикселей, в то время как большинство сверточных нейронных сетей, том числе и U-Net, разработано для работы с изображениями размером 256×256 пикселей. При разделении больших изображений на более мелкие фрагменты, время обработки увеличивается пропорционально количеству фрагментов. Для эффективной сегментации больших изображений необходимо увеличивать производительность сети, сохраняя при этом необходимую точность.

Один из способов повышения производительности этой архитектуры заключается в применении высокопроизводительных кодеров. В настоящее время сеть MobileNet [111] является одним из таких кодеров. Она снижает потребление памяти для вычислений, сохраняя высокую точность прогнозов. Эта предварительно обученная сеть даже может использоваться на мобильных

устройствах. В работе предлагается для сегментации спутниковых изображений модифицировать архитектуру сети U-Net, и в качестве кодера, использовать сеть MobileNet. Предлагаемая архитектура названа MobileNet-Unet и показана на Рисунок 3.18.

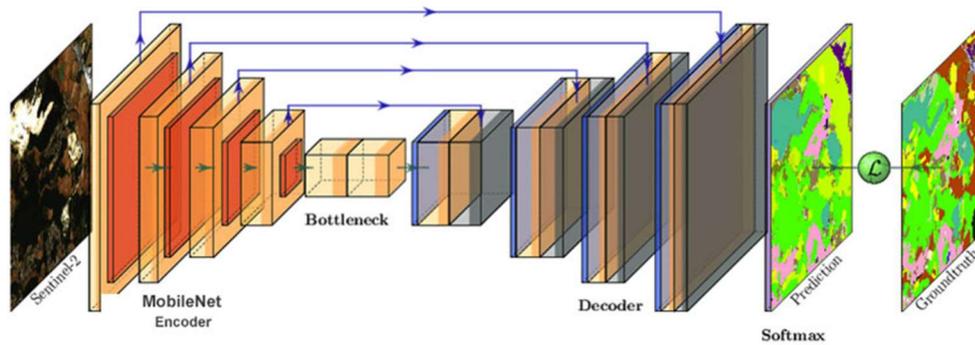


Рисунок 3.18. Архитектура MobileNet-Unet

MobileNet, используемая в качестве кодера, представляет собой конволюционную сеть, специально разработанную для использования, например, на мобильных устройствах с ограниченными вычислительными ресурсами. Она была представлена исследователями Google в 2017 году. Основная идея MobileNet заключается в использовании "глубоких свертков" (depthwise separable convolutions), которые позволяют выполнять свертки с меньшим количеством параметров, чем традиционные сверточные слои. Это позволяет уменьшить количество вычислений и количество параметров модели, что делает ее более легкой и быстрой.

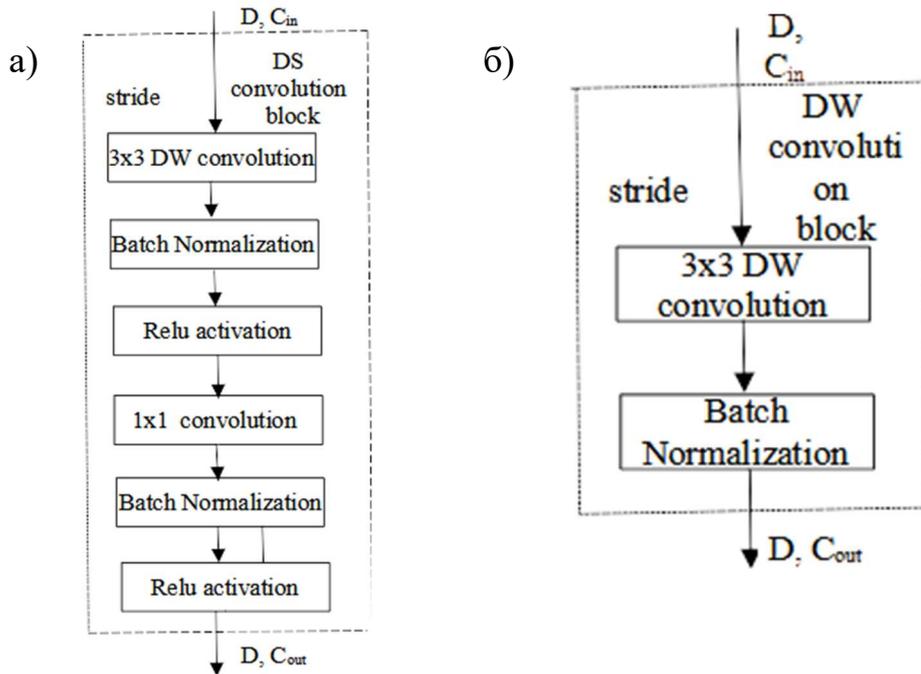


Рисунок 3.19. Сверточные блоки: а) блок глубинной разделяемой свертки (DS); б) блок глубинной свертки (DW);  $D$  – размерность изображения,  $C_{in}$ ,  $C_{out}$  — количество входных и выходных каналов, stride — шаг свертки

Архитектура MobileNet базируется на использовании глубинной разделяемой свертки (DSW - depthwise separable convolution), которая разделяет стандартную свертку на две части: глубинную свертку (DW - depthwise convolution) и точечную свертку  $1 \times 1$  (pointwise convolution). В отличие от стандартной свертки, которая одновременно обрабатывает и объединяет входные данные в новый набор выходных данных за один проход, этот метод разделяет эти операции для повышения эффективности. Глубинная разделяемая свертка выполняется в два этапа. На первом этапе каждый входной канал подвергается обработке отдельным фильтром с использованием глубинной свертки. На втором этапе выходные данные от глубинной свертки объединяются с помощью точечной свертки. Это позволяет разделить стандартную свертку на два слоя: один для фильтрации и другой для объединения. Такой подход существенно снижает вычислительную нагрузку и размер модели [124].

Архитектура сети включает два вида блоков, изображенных на Рисунке 3.19. Первый тип реализует глубинную разделяемую свертку (DSW) с использованием

пакетной нормализации и активации ReLU. Второй тип представляет собой глубинную свертку с пакетной нормализацией и такой же функцией активации. В основном, в этих блоках используется свертка с шагом 1 ( $\text{stride} = 1$ ), в то время как свертка со шагом 2 ( $\text{stride} = 2$ ) используется для уменьшения пространственной размерности. Из сверточных блоков формируются два основных типа сверточных уровней. Структура блоков первого и второго типов показана на Рисунке 3.20 и 3.21. Особенностью базового блока первого типа является использование остаточного соединения (residual connection). По этому принципу результат применения последовательных сверток типа DS и DW суммируется с результатом отдельной глубинной свертки.

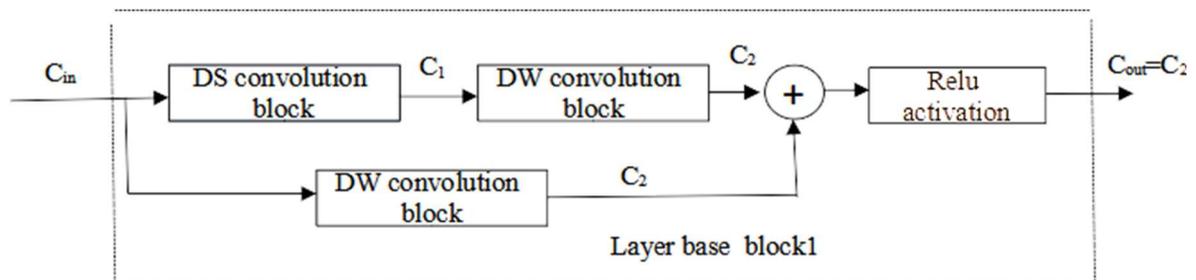


Рисунок 3.20. Структура базового блока первого типа сверточного уровня.  $C_{in}$  и  $C_{out}$  обозначают количество входных и выходных каналов, а  $C_1$  и  $C_2$  представляют количество каналов в глубинной разделяемой свертке и глубинной свертке соответственно

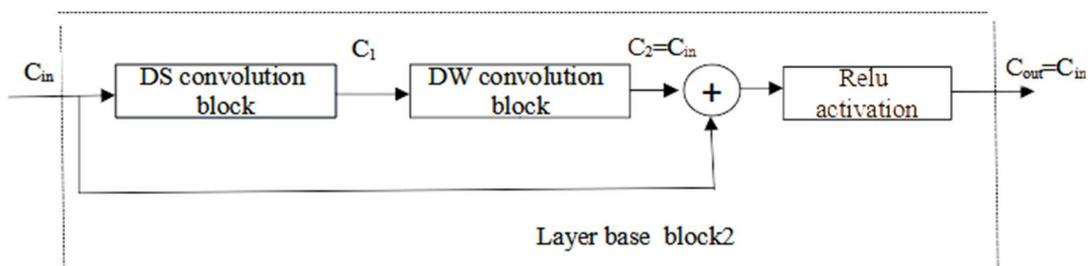


Рисунок 3.21. Структура базового блока второго типа сверточного уровня.  $C_{in}$  и  $C_{out}$  обозначают количество входных и выходных каналов, а  $C_1$  и  $C_2$  представляют количество каналов в глубинной разделяемой свертке и глубинной свертке соответственно

Каждый сверточный слой в составе сети создается путем комбинирования этих базовых блоков. На Рисунок 3.22 представлена структура сверточного слоя сети, включающего в себя базовый блок первого типа и N базовых блоков второго типа.

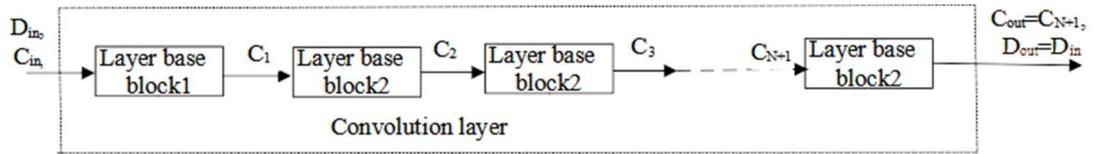


Рисунок 3.22. Сверточный слой сети.  $D_{in}$  и  $D_{out}$  обозначают размерности входных и выходных карт признаков, а  $C_{in}$  и  $C_{out}$  представляют входное и выходное количество каналов.  $C_1$  обозначает количество каналов в базовом блоке первого типа, а  $C_2, \dots, C_{N+1}$  - количество каналов в соответствующих блоках второго типа

Начальная часть сети кодирования начинается с обычного сверточного слоя, использующего ядро размером  $3 \times 3$  и шаг свертки 2, с последующим применением пакетной нормализации и операцией максимального пулинга. Затем следуют несколько сверточных слоев, где каждый слой представлен последовательностью базовых блоков сверточного уровня, как показано на Рисунке 3.22. Каждый последующий слой увеличивает количество фильтров и уменьшает пространственные размеры карт признаков.

В данной работе предлагается использовать кодер, состоящий из 4 сверточных слоев. Параметры этих сверточных слоев приведены в таблице 3.1. Кодер работает со входными изображениями размерностью  $512 \times 512$  и представляет собой модификацию сети MobileNet для мобильных устройств в части количества слоев и их параметров. Такая модификация позволяет работать с более крупными частями изображений, что позволяет провести более детальную сегментацию больших спутниковых изображений [124].

Таблица 3.1. Параметры сверточных слоев в кодировщике

Номер слоя	Размерность входа $D_{in}$	Размерность выхода $D_{out}$	Число каналов в входа $C_{in}$	Число каналов в выхода $C_{out}$	Количество блоков типа 1	Количество блоков типа 2
1	512	128	3	64	-	-
2	128	128	64	256	1	2
3	128	64	256	512	1	3
4	64	32	512	1024	1	5

Декодирующая часть сети состоит из нескольких уровней, где каждый уровень начинается с увеличения размерности входной карты признаков и объединения этого результата с картой признаков, полученной с предыдущего уровня кодировщика. Затем объединенный результат подвергается глубинным сверткам с использованием пакетной нормализации и функции активации Relu. На Рисунке 3.23 показана структура декодирующего слоя сети, используемая в данной работе.

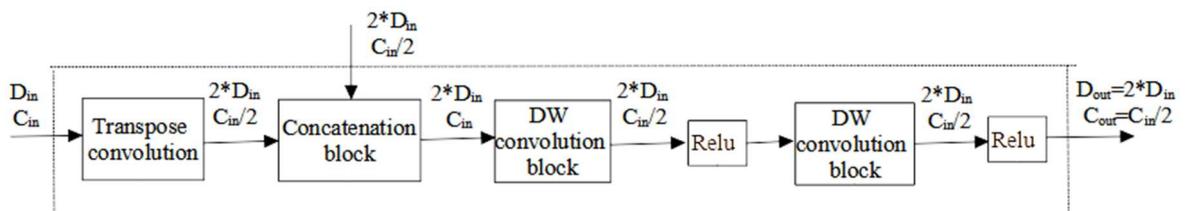


Рисунок 3.23. Структура декодирующего слоя.  $D_{in}$ ,  $D_{out}$  — размерности входных и выходных карт признаков;  $C_{in}$ ,  $C_{out}$  — входное и выходное количество каналов

Для увеличения размерности входной карты признаков применяется свертка транспонирования, которая удваивает размерность, но сокращает количество каналов вдвое. Эти изменения помогают согласовать размерность и количество каналов с картой признаков, поступающей с предыдущего слоя кодера. После

объединения этих карт создается новая карта признаков, размер которой соответствует размерности соответствующего слоя кодера, а количество каналов равно числу каналов входа. Эту полученную карту признаков обрабатывают с помощью двух блоков глубинной свертки. Выход декодирующего слоя представляет собой карту признаков, которая передается на следующий слой декодирования. В последнем декодирующем слое входными данными служат карта признаков предпоследнего слоя декодера и исходное изображение. Этот слой включает дополнительную глубокую свертку, количество каналов в которой соответствует числу классов, которые необходимо распознать на изображении. Для активации используется сигмоидальная функция. Выход этого слоя представляет собой "тепловую" карту, которая визуализирует сегментированное изображение.

Применение в кодирующей и декодирующих частях предлагаемой сети глубинных сверток существенно уменьшает число параметров, настраиваемых при обучении сети и использующихся затем при ее работе, что позволяет снизить требования к вычислительным ресурсам и повысить ее быстродействие.

Процедура обучения предлагаемой сети и результаты ее использования описаны в главе 4.

### **3.6. Методика определения сельскохозяйственных угодий**

Карты землепользования или карты почвенно-растительного покрова являются основным инструментом управления информацией о поверхности земли и взаимодействии между различными типами почвенно-растительного покрова. В Узбекистане до 1990-х годов большая часть информации о землепользовании поступала из Национальной картографо-геодезической программы. Карты землепользования используются не только для управления земельными ресурсами, но также важны для экологических целей, таких как землепользование, изменение землепользования и лесное хозяйство, в политике изменения климата и исследованиях биоразнообразия.

Основная цель этого исследования - проверить возможность использования данных спутниковых датчиков для точного картирования основных типов орошаемых культур с использованием алгоритмов глубокого обучения. Для достижения этой цели необходимо:

- составить карту и сравнить производительность алгоритмов глубокого обучения, таких как U-net и VGG19, для основных орошаемых пахотных земель по типам культур на основе данных Google Earth и Sentinel среднего и высокого разрешения;
- провести тестирование различных комбинаций вегетационных индексов, таких как NDVI, EVI и SAVI, в качестве исходных данных для получения классификации типов культур;
- сравнить площади всех полученных карт землепользования сельскохозяйственного назначения с данными ОСС Госкомстата РУз.

Это исследование посвящено некоторым городам и Ташкентской области в центральноазиатской стране Узбекистан. Сельскохозяйственные угодья составляют около 62 процентов от общей площади страны, большая часть которых - пастбища. Обрабатываемые земли занимают лишь 10 процентов от общей площади страны, составляющей около 425 квадратных километров [112]. Регион граничит с Казахстаном на севере и северо-западе, с Кыргызстаном на северо-востоке, с Наманганской областью на востоке, с Таджикистаном на юге и с Сырдарьинской областью на юго-западе. Учитывая, что пахотные земли в основном распространены в низменных районах этого региона, анализ был ограничен именно этими районами (Рисунок 3.24).

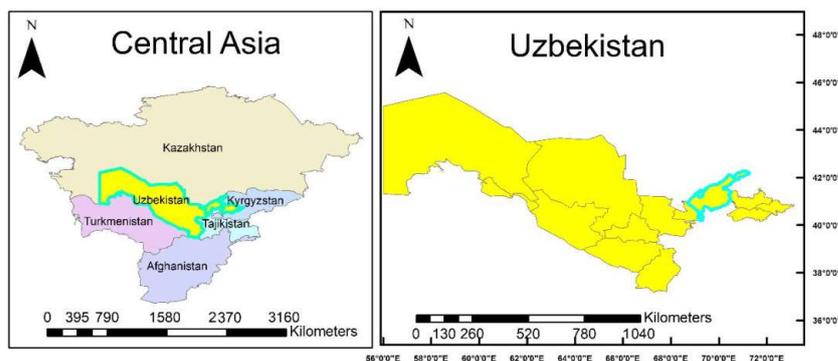


Рисунок 3.24. Географическое расположение региона исследования

Характер климата характеризуется типичным континентальным режимом, с прохладной и влажной зимой, а также жарким, сухим и продолжительным летом; средние температурные показатели варьируются от  $-1^{\circ}\text{C}$  до  $-2^{\circ}\text{C}$  в январе и достигают  $26,8^{\circ}\text{C}$  в июле. Общее количество осадков в течение года составляет примерно 300 мм на равнинах, от 300 до 400 мм в предгорьях и от 500 до 600 мм в горных районах. Основные осадки приходят в начале весны, а в альпийских районах они выпадают в виде снега. Река Сырдарья и ее притоки, Чирчик и Ахангаран, в основном питаются таянием снега и ледников, и используются для орошения и производства гидроэлектроэнергии. Примерно 40 процентов орошаемых земель в Узбекистане используются для выращивания пшеницы, 36 процентов занимают хлопковые культуры, а оставшиеся 24 процента отводятся под другие культуры, такие как фрукты, овощи, скотоводство и различные виды зерновых. В Ташкентской области доля посевных площадей под хлопком и пшеницей составляет более 61 процента от общего объема в 2018 году.

Данные S2 и L8 (Sentinel 2 и Landsat 8), охватывающие соответствующий регион исследования, представляют собой мультиспектральные изображения необходимые для вычисления вегетационных индексов. (Алгоритмы вычисления вегетационных индексов описаны в разделе 2.3.) Эти данные были загружены с сайта Google Earth Engine для нескольких дат периода роста растительности с мая по октябрь 2018 г. Кроме того, в этот период доступны только изображения без облаков. Спецификацию спектральных полос для двух сенсорных систем, использованных в анализе, можно увидеть в Рисунок 3.25 [114].

Band Number	S2 MSI			L8 OLI		
	Description	Wave-Lengths (nm)	Spatial Resolution (m)	Description	Wave-Lengths (nm)	Spatial Resolution (m)
1	Coastal aerosol	433CE453	60	Coastal aerosol	433CE453	30
2	Blue	458CE523	10	Blue	450CE515	30
3	Green	543CE578	10	Green	525CE600	30
4	Red	650CE680	10	Red	630CE680	30
5	Vegetation Red Edge 1	698CE713	20	NIR	845CE885	30
6	Vegetation Red Edge 2	733CE748	20	SWIR 1	1570CE1650	30
7	Vegetation Red Edge 3	773CE793	20	SWIR 2	2100CE2300	30
8	Near-Infrared (NIR)	785CE900	10	Panchromatic	500CE680	15
8a	Narrow NIR	855CE875	20			
9	Water vapor	935CE955	60	Cirrus	1360CE1390	30
10	SWIR-Cirrus	1360CE1390	60	Thermal Infrared (TIRS) 1	10,600CE11,200	100
11	SWIR 1	1565CE1655	20	Thermal Infrared (TIRS) 2	11,500CE12,500	100
12	SWIR 2	2100CE2280	20			

Рисунок 3.25. Спецификации спектральных полос для S2 и L8

После загрузки изображения S2 каналы SWIR 1 и SWIR 2 были передискретизированы до разрешения 10 м. Затем данные L8 и S2 были скорректированы с учетом атмосферы от отражательной способности верхней части атмосферы (ТОА) до поверхностной отражательной способности. Это было проведено с использованием программы Sen2Core из пакета Sentinel Hub. Затем все плитки S2 и L8 объединяются для каждого месяца отдельно и отображаются в изучаемую область. Преобразованные, таким образом, данные используются для расчета индексов NDVI, EVI, NDWI и SAVI. В итоге получены месячные временные профили NDVI, EVI, NDWI и SAVI, которые являются исходными данными для классификаторов ML.

### 3.7. Нейронная сеть для классификации сельскохозяйственных культур

Для идентификации сельскохозяйственных культур широко применяются сверточные нейронные сети (CNN), так как они эффективно справляются с классификацией изображений разнообразных типов. В этом контексте можно выделить несколько вариантов CNN и рассмотреть их характеристики при применении к классификации сельскохозяйственных культур [115]:

#### 1. LeNet-5:

- Это одна из первых сверточных нейронных сетей, разработанных Яном ЛеКуном.

- Состоит из нескольких слоев свертки и пулинга, а также полносвязанных слоев в конце.
- Обычно используется для задач классификации с небольшим количеством классов.

## 2. AlexNet:

- Разработана в 2012 году и стала пионером в области глубокого обучения и CNN.
- Содержит несколько слоев свертки и пулинга, а также слои нормализации и дропаута для предотвращения переобучения.
- Широко используется для классификации изображений, включая сельскохозяйственные культуры.

## 3. VGG (Visual Geometry Group) Net:

- Имеет очень глубокую архитектуру с использованием малых 3x3 сверток.
- Простая и эффективная архитектура, легко адаптируемая к различным задачам классификации.
- Используется для классификации изображений в различных областях, включая сельское хозяйство.

## 4. ResNet (Residual Neural Network):

- Вводит понятие "остаточных блоков", что позволяет обучать глубокие нейронные сети без проблемы затухания градиента.
- Показывает высокую эффективность при классификации изображений и может быть успешно применена к сельскохозяйственным данным.

## 5. Inception (GoogLeNet):

- Имеет модульный дизайн с использованием параллельных сверток разных размеров.
- Позволяет эффективно использовать ресурсы и улучшает качество классификации.

- Применяется для классификации изображений сельскохозяйственных угодий и культур.

В этом проекте для классификации сельскохозяйственной продукции использовалась нейронная сеть VGG.

VGG (Visual Geometry Group)Net - это сверточная нейронная сеть, разработанная исследователями из Visual Geometry Group при Университете Оксфорда. Эта нейронная сеть получила широкое признание за свою простоту и высокую производительность в задачах классификации изображений. Модель VGG19 (также известная как VGGNet-19) имеет ту же основную идею, что и модель VGG16, за исключением того, что она поддерживает 19 слоев. Числа «16» и «19» относятся к весовым слоям модели (сверточным слоям). По сравнению с VGG16, VGG19 содержит три дополнительных сверточных слоя. При построении сети VGG используются очень маленькие сверточные фильтры. Тринадцать сверточных слоев и три полносвязных слоя составляют VGG.

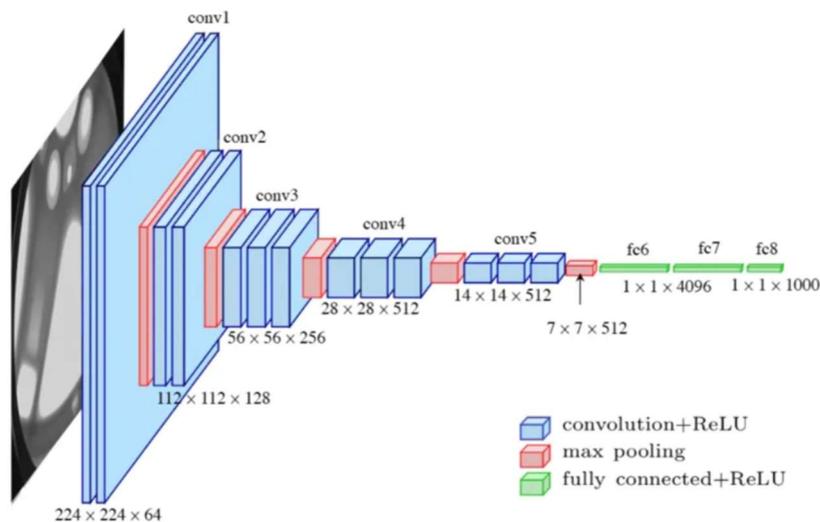


Рисунок 3.26. Архитектура VGG-Net

Рассмотрим архитектуру VGG:

- **Входные данные.** VGGNet принимает в качестве входных данных изображения размером  $224 \times 224$  пикселя. Чтобы поддерживать постоянный размер входных данных ImageNet.

- Сверточные слои. Сверточные слои в VGGNet представлены последовательно расположенными сверточными операциями с использованием фильтров 3x3 и функцией активации ReLU. После каждого сверточного слоя следуют слои пулинга (MaxPooling).
- Полносвязанные слои. После серии сверточных и пулинговых слоев следуют полносвязанные слои для классификации. В конце нейронной сети обычно находится полносвязанный слой с функцией активации softmax для предсказания вероятностей принадлежности к различным классам.

Архитектура VGGNet проста в понимании и реализации, что облегчает ее использование и модификацию. В целом, нейронная сеть VGG отличается от других нейронных сетей своей глубокой архитектурой, использованием небольших сверточных фильтров, простой и единообразной структурой, а также высокой производительностью на различных задачах классификации изображений.

В данной работе для сокращения вычислительных затрат предлагается модификация архитектуры используемой сети VGG. Модификация заключается в замене во всех сверточных слоях сети обычных сверток на глубокие свертки. Такая модификация позволяет существенно уменьшить число параметров, настраиваемых при обучении сети и используемых затем при ее работе, что позволяет снизить требования к используемым вычислительным ресурсам и повысить ее быстродействие.

В этой работе, для обучения такой модифицированной сети, использовался датасет, в котором каждому классу сельскохозяйственных культур соответствовало 160 изображений размером 224x224 пикселей. Процедура обучения предлагаемой сети и результаты ее использования описаны в главе 4.

### **3.8. Методика обнаружения активной урбанистской территории**

Обнаружение активной урбанистской территории — это процесс идентификации и анализа областей городской среды, которые активно

используются людьми или подвержены значительным изменениям в различные периоды времени. Этот процесс можно выполнить следующим образом:

1. Подготовка данных:

- Формирование коллекции изображений, содержащих различные городские среды. В проекте было использовано около 13 000 изображений.
- Разметка изображений в соответствии с распознаваемыми классами объектов. Обычно это делается вручную путем прослеживания границ объектов. В проекте используются уже размеченные изображения. Общее количество классов объектов - 21 класс.

2. Выбор архитектуры модели для сегментации изображений. В проекте предложено использовать архитектуру на базе сетей U-Net и MobileNet.

3. Подготовка набора обучающих данных:

- Разделение изображений и их меток на наборы обучающих и тестовых данных: изображения разбиваются на фрагменты и распределяются по папкам Train, Test и Validation.
- Изображения и их характеристики преобразуются в формат, подходящий для обучения модели – в формат, принимаемый нейронной сетью.

4. Обучение модели:

- Выбранная модель должна быть обучена на наборе обучающих данных. Во время обучения модель корректирует свои параметры, чтобы точно предсказать типы сегментируемых областей на изображениях.
- Для обучения модели обычно используются выбираемые функция потерь и метод оптимизации поиска параметров. В проекте используется функции потерь связанная с коэффициентом Дайса, а для оптимизации применяется алгоритм оптимизации Адама.

5. Оценка модели:

- Расчет достигнутых параметров качества сегментации и визуализация результатов сегментации, также оценка производительности модели.

#### 6. Применение модели:

- Применение обученной модели для сегментации новых изображений городской среды.
- Использование результаты сегментации для дальнейшего анализа, например, для картографирования городских областей, анализа планирования городской инфраструктуры и т. д.

Семантическая сегментация с помощью нейронных сетей широко используется при обнаружении активных городских территорий, поскольку позволяет точно идентифицировать различные классы объектов на изображении, включая активные и неактивные города. Поэтому в этом проекте процесс сегментации был реализован на основе архитектуры нейронной сети. Результаты, полученные с помощью нейронной сети, представлены в главе 4.

### 3.9. Оценки качества результатов

Оценка качества — это процесс оценки результатов применения модели или алгоритма путем сравнения его выходных результатов с истинными значениями (золотым стандартом). Это важный этап в разработке и оценке любой модели машинного обучения или алгоритма, так как позволяет понять, насколько хорошо модель способна делать предсказания и как она обобщается на новые данные. Ключевые метрики, используемые для оценки качества моделей машинного обучения [116]:

1. Точность измеряет долю правильных предсказаний модели по отношению к общему количеству предсказаний. Формально, это количество правильных предсказаний, разделенное на общее количество предсказаний:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

где TP (True Positive) - количество истинно положительных предсказаний, TN (True Negative) - количество истинно отрицательных предсказаний, FP (False Positive) - количество ложно положительных предсказаний и FN (False Negative) - количество ложно отрицательных предсказаний.

## 2. Точность классификации (Precision):

Это метрика, используемая в задачах классификации, которая измеряет долю правильных предсказаний модели по отношению к общему числу примеров.

Это просто доля правильно классифицированных примеров.

$$precision = \frac{TP}{TP + FN} \quad (3.2)$$

## 3. Полнота (Recall):

Доля правильно распознанных объектов основного класса среди всех объектов основного класса из выборки. Полнота - вероятность правильной классификации при принадлежности образа данному классу.

$$recall = \frac{TP}{TP + FN} \quad (3.3)$$

## 4. Чувствительность (sensitivity) – вероятность дать правильный ответ для образов основного класса.

$$sensitivity = \frac{TP}{FP + TN} \quad (3.4)$$

Точная оценка качества модели имеет решающее значение для успешного глубокого обучения. Для оценки качества модели CNN используется несколько методов:

1. Матрица путаницы (Confusion Matrix). Это таблица, которая позволяет визуализировать качество классификационной модели, путем сравнения фактических и предсказанных классов для набора данных. Она является основой для расчета различных метрик качества классификации. Матрица путаницы обычно представляет собой квадратную матрицу, где строки

представляют фактические классы, а столбцы - предсказанные классы. Рассмотрим пример матрицы путаницы для бинарной классификации:

<b>Фактический класс</b>	<b>Negative</b>	<b>Positive</b>
<b>Negative</b>	TN	FP
<b>Positive</b>	FN	TP

Таблица 3.2. Матрицы путаницы для задач бинарной классификации

где:

- TN (True Negative): количество верно предсказанных отрицательных примеров.
- FP (False Positive): количество ложно положительных предсказаний (отрицательные примеры, но предсказанные как положительные).
- FN (False Negative): количество ложно отрицательных предсказаний (положительные примеры, но предсказанные как отрицательные).
- TP (True Positive): количество верно предсказанных положительных примеров.

Матрица путаницы позволяет анализировать качество модели, выявлять типы ошибок, которые она делает, и рассчитывать различные метрики качества, такие как точность, полнота, F1-мера и др., на основе значений, содержащихся в матрице.

2. Перекрёстная проверка (Cross-Validation) — это метод оценки качества модели машинного обучения, который позволяет более надёжно оценить обобщающую способность модели на новых данных. Основная идея перекрестной проверки заключается в разделении доступных данных на несколько частей (называемых "складками" или "фолдами"), обучении

модели на одной части и проверке её на оставшихся частях. Существует несколько различных подходов к перекрёстной проверке, но одним из наиболее распространённых является K-fold Cross-Validation, который включает в себя следующие шаги:

1. Разделение данных:

- Исходный набор данных разделяется на K равных частей (фолдов).

2. Итерации обучения и оценки:

- Для каждой итерации, один из фолдов используется в качестве тестового набора данных, а остальные K-1 фолдов используются в качестве обучающего набора данных.
- Модель обучается на обучающем наборе и оценивается на тестовом наборе.

3. Усреднение метрик:

- Результаты оценки (например, значения метрик качества) усредняются по всем K итерациям, чтобы получить общую оценку производительности модели.

Преимущества перекрёстной проверки:

- Позволяет лучше оценить обобщающую способность модели, так как каждый образец данных используется как в обучении, так и в тестировании.
- Уменьшает вероятность переобучения модели на конкретном наборе данных.
- Обеспечивает более стабильную оценку производительности модели, так как оценка проводится на нескольких различных разбиениях данных.

4. Оценка тестового набора данных — это процесс оценки качества модели машинного обучения на отложенных данных, которые модель не видела во время обучения. Это важный шаг в разработке моделей, так как

позволяет оценить способность модели к обобщению на новые, ранее не встречавшиеся данные.

Оценка точности в архитектуре U-Net, как и в любой другой архитектуре нейронной сети, может быть выполнена с использованием различных метрик, в зависимости от типа задачи, набора данных и требований к модели. Типичные метрики, которые можно использовать для оценки точности модели U-Net [117]:

#### 1. Индекс сходства Дайса (Dice Similarity Coefficient):

- Это метрика, которая измеряет степень сходства между двумя областями. В случае сегментации изображений, индекс Дайса используется для оценки сходства между истинными и предсказанными масками.
- Формула для расчета:

$$Dice = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (3.5)$$

где A - истинная маска, B - предсказанная маска,  $|\cdot|$  обозначает мощность множества.

#### 2. Пересечение по объединению (Intersection over Union, IoU):

- Это ещё одна метрика для измерения степени перекрытия между истинной и предсказанной масками.
- Формула для расчета:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (3.6)$$

#### 3. Точность (Accuracy):

- В контексте сегментации изображений, точность измеряет долю пикселей, которые были правильно классифицированы.
- Формально, это отношение числа правильно классифицированных пикселей к общему числу пикселей на изображении.

#### 4. Средняя точность (Mean Accuracy):

- Это усредненное значение точности по всем классам.

## 5. Средняя ошибка (Mean Error):

- Это метрика, которая измеряет среднее расстояние между истинной и предсказанной масками.

## 6. Среднее расстояние до контура (Mean Distance to Boundary):

- Это метрика, которая измеряет среднее расстояние от пикселей в предсказанной маске до ближайшего пикселя в истинной маске.

7. Индекс Жаккара (Jaccard Index), также известный как коэффициент пересечения или мера сходства Жаккара, является метрикой, используемой для оценки сходства между двумя наборами данных. В контексте сегментации изображений он используется для измерения степени перекрытия (по площади) между истинной и предсказанной масками. Формула для расчета индекса Жаккара (Jaccard Index) выглядит следующим образом и совпадает с расчетом метрики IoU:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (3.7)$$

где:

- $A$  — это множество пикселей в истинной маске,
- $B$  — это множество пикселей в предсказанной маске,
- $|\cdot|$  обозначает мощность множества.

Индекс Жаккара находится в диапазоне от 0 до 1, где 0 обозначает полное отсутствие пересечения между масками, а 1 обозначает их полное совпадение.

Эти метрики обычно используются в задачах компьютерного зрения для оценки эффективности моделей классификации или сегментации, таких как CNN. Точная оценка качества модели имеет решающее значение для успешного глубокого обучения, и для надежной оценки качества модели следует использовать различные методы оценки точности. Использование метрик оценки в функции потерь (индекс Жаккара, IoU и т. д.) помогает правильно оптимизировать обучение модели в нейронных сетях.

### Выводы к главе 3

1. Данные для этого проекта предлагается получать с платформ Sentinel Hub и Google Earth. Потому что две платформы открыты для использования и позволяют загружать изображения высокого качества. Первичную коррекцию атмосферы можно выполнить на основе дополнительных настроек на платформах, если это невозможно, коррекцию атмосферы следует выполнить методом, основанным на нейронных сетях. Все спутниковые изображения проекта были сделаны с территории Республики Узбекистан.
2. Следует отметить, что архитектура кодер-декодер становится все более популярной при семантической сегментации благодаря своей высокой гибкости и производительности. Поэтому в этом проекте используются U-Net и MobileNet с архитектурой кодировщика-декодера в процессе атмосферной коррекции, сегментации городских и сельскохозяйственных земель. Стандартная архитектура кодера-декодера использовалась для атмосферной коррекции, а базовая архитектура U-Net использовалась для отслеживания городских и сельскохозяйственных объектов, обнаружения объектов и мониторинга городских изменений. Для достижения лучших результатов это было достигнуто на основе модификации архитектуры U-Net, то есть кодирующая часть архитектуры U-Net была заменена кодирующей частью архитектуры MobileNet. Таким образом, результат улучшен, и все результаты представлены в 4 главах.
3. Процесс семантической сегментации был реализован для классификации и идентификации сельскохозяйственной продукции. Процесс классификации основан на нейронной сети и реализован с использованием архитектуры VGG 19. Перед обучением нейронной сети изображения сегментировались по индексу VI. После анализа индексов NDVI, SAVI и EVI полученные данные были обучены с использованием архитектуры нейронной сети VGG

19. Архитектура VGG 19 имеет лучшую и более быструю производительность, чем другие архитектуры. Причина в том, что эта архитектура состоит из большего количества слоев, т.е. 13 мини-фильтров.
4. Для сегментации и классификации областей и объектов предлагается использовать нейронные сети с архитектурами U-Net, MobileNet и VGG. Все эти архитектуры на основе были выбраны исходя из скорости, качества результатов, простоты и, главное, снижения нагрузки на вычислительные ресурсы.

## **ГЛАВА 4. РЕАЛИЗАЦИЯ И ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДОВ МОНИТОРИНГА ТЕРРИТОРИИ НА ОСНОВЕ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ**

Мониторинг территории на основе спутниковых изображений предполагает использование спутниковых изображений для мониторинга текущего состояния территории, а также для отслеживания изменений в конкретном географическом месте с течением времени. В этом проекте экспериментально проанализированы возможности мониторинга сельской и городской территории на основе сегментации и обработки спутниковых данных. При этом:

1. Нейронные сети использовались для атмосферной коррекции спутниковых изображений.
2. Были использованы новые методы мониторинга сельскохозяйственных угодий и идентификации сельскохозяйственной продукции.
3. Результат был получен на основе интеграции нейронных сетей в мониторинг городских территорий и обнаружение объектов.

В этой главе представлены результаты вышеуказанных методов.

### **4.1. Средства мониторинга территории**

#### **4.1.1. Атмосферная коррекция на основе нейронной сети**

Наиболее подходящей архитектурой сети для такого преобразования является архитектура кодер – декодер. Структура предлагаемой нейронной сети показана в главе 3 (Рисунок 3.15). Кодер имеет только три уровня кодирования. Фактически кодер это обычная сверточная сеть, обучаемая для классификации входного изображения. Декодер имеет такое же количество слоев и выполняет

функцию интерполяции выхода кодера слой декодирования (Рисунок 3.15), представляет собой обратную свертку с последующей пакетной нормализацией. Датасет для обучения и тестирования нейронной сети формируется на базе доступных спутниковых изображений уровней L1C и L2A для нескольких регионов земной поверхности, полученных в различные времена года. При этом используются данные спектральных каналов B04 (R), B03 (G), B02 (B) видимого диапазона и данные канала B08 (NIR) ближнего инфракрасного диапазонов. Данные этих каналов предварительно обрабатываются и преобразуются в четырехканальные изображения. Структура алгоритма предварительной обработки описана в главе 3 (Рисунок 3.16). Сначала изображения каналов приводятся к одинаковой размерности, затем разделяются на 64 части, нормализуются по яркости и формируют 64 четырехканальные изображения. Полученный таким образом набор изображений разделяется случайным образом на обучающую, валидационную и тестовую выборки, содержащие соответственно 80%, 10% и 10% от объема датасета.

При формировании датасета было использовано 355 изображений уровня L1C и такое же количество, соответствующих им изображений уровня L2A, каждое размерностью около 2048x2048 пикселей. Таким образом сеть обучалась и тестировалась на наборе из 22720 четырехканальных изображениях уровня L1C размерностью 128x128 пикселей, а соответствующие им изображения уровня L2A являлись целевыми. Набор исходных мультиспектральных изображений загружен с Sentinel Hub и содержит данные для нескольких регионов Узбекистана за 3 года. При обучении сети в качестве функции потерь использовалась среднеквадратичная ошибка MSE. Данная среднеквадратическая ошибка и представляет собой оценку точности атмосферной коррекции. Для поиска параметров сети применялся алгоритм оптимизации Adam.

Результаты обучения сети на использованном датасете показаны на Рисунок 4.1. При этом удалось достичь точности коррекции около 99.5%. На Рисунок 4.2 показан пример визуализации результатов коррекции с использованием нейронной сети.

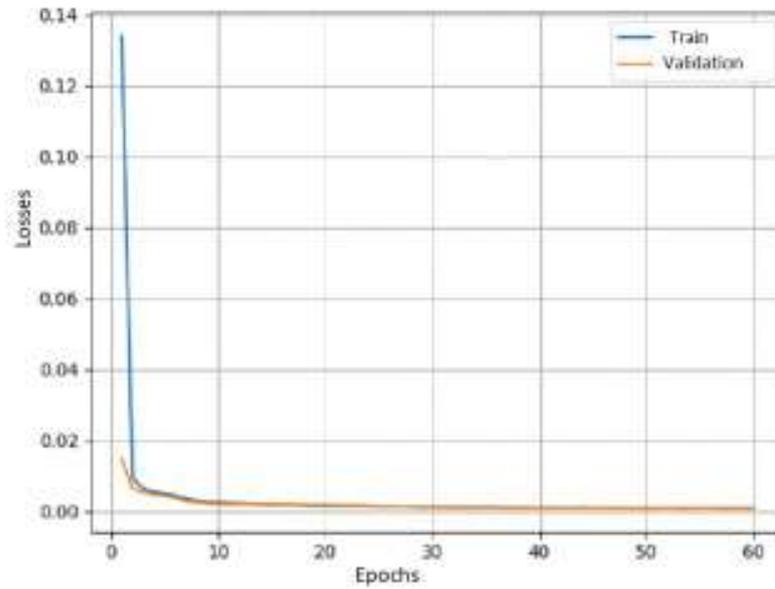


Рисунок 4.1. Зависимость потерь (среднеквадратической ошибки) от эпохи обучения

a)



b)



Рисунок 4.2. Изображения уровней 1С и 2А: (a) Изображение без атмосферной коррекции — уровень L1С; (b) Атмосферная коррекция с помощью нейронной сети

При проведении атмосферной коррекции, кроме трехканального изображения в формате RGB, отражающее скорректированную видимую часть спектра, формируется также одноканальное NIR изображение, представляющее скорректированный ближний инфракрасный диапазон спектра. Эти изображения необходимы, в том числе, для расчетов вегетационных индексов.

При проведении исследований, с помощью данной сети, обрабатывались также спутниковые снимки не только с Sentinel, но и с других спутников. Результаты показали, приемлемую точность коррекции для этих «сторонних» для нейронной сети изображений.

## **4.2. Нейронные сети для семантической сегментации спутниковых изображений**

Семантическая сегментация спутниковых изображений с помощью нейронных сетей предполагает присвоение каждому пикселю изображения метки, указывающей на класс объектов, к которому он принадлежит. Это включает в себя картографирование растительного покрова, мониторинг городских изменений и анализ урожая.

В данной работе для семантической сегментации исследовалась предложенная архитектура сети MobileNet-Unet, описанная в разделе 3.5. Результаты ее работы сравнивались с результатами работы сети с архитектурой Unet, которая обычно используется в задачах семантической сегментации. Для того, чтобы такое сравнение было адекватным, обучение обеих сетей проводилось на одном и том же датасете.

### **4.2.1. Датасет и предварительная обработка**

Для обучения сетей использовался предварительно подготовленный набор данных LandCover [118], дополненный снимками, относящимися к районам

Центральной Азии. Однако эти дополнительные снимки были без атмосферной коррекции. Поэтому для них была проведена атмосферная коррекция с использованием сети, предложенной в данной работе. В целом набор содержит 1146 спутниковых изображений районов земной поверхности высокого разрешения. Помимо самих изображений в него входят маски, отображающие тип земной поверхности для каждого пикселя соответствующего изображения. В наборе данных присутствуют следующие типы — сельскохозяйственные земли, пастбища, бесплодные земли, здания и сооружения, лесные массивы, водные массивы. Остальные типы поверхности, не входящие в этот перечень, отображаются как неизвестный тип.

Спутниковые изображения с высоким разрешением слишком велики, чтобы их можно было обработать непосредственно на нейронной сети. Простое уменьшение масштаба исходных изображений приведет к потере точности сегментации. Поэтому первым этапом предварительной обработки является разделение изображений набора данных и соответствующих им масок на фрагменты. При проектировании сети была выбрана размерность входных изображений 512x512 пикселей, которая позволяет с одной стороны уменьшить вычислительные затраты при обучении и использовании сети, а с другой стороны обеспечит достаточную точность сегментации. Полученные фрагменты изображений и масок масштабируются до указанной размерности. В данной работе каждое исходное изображение разбивается на 16 фрагментов.

На Рисунок 4.3 показан алгоритм предварительной обработки изображений, входящих в состав исходного датасета. Датасет состоит из спутниковых RGB изображений определенных территорий и соответствующих им масок. Каждая маска представляет собой изображение в формате RGB, с заданным количеством цветов  $N$ . При этом каждый тип земной поверхности отображается в маске своим определенным заранее цветом, содержащимся в таблице используемых цветов. Таким образом количество цветов  $N$  в маске соответствует количеству типов земной поверхности.

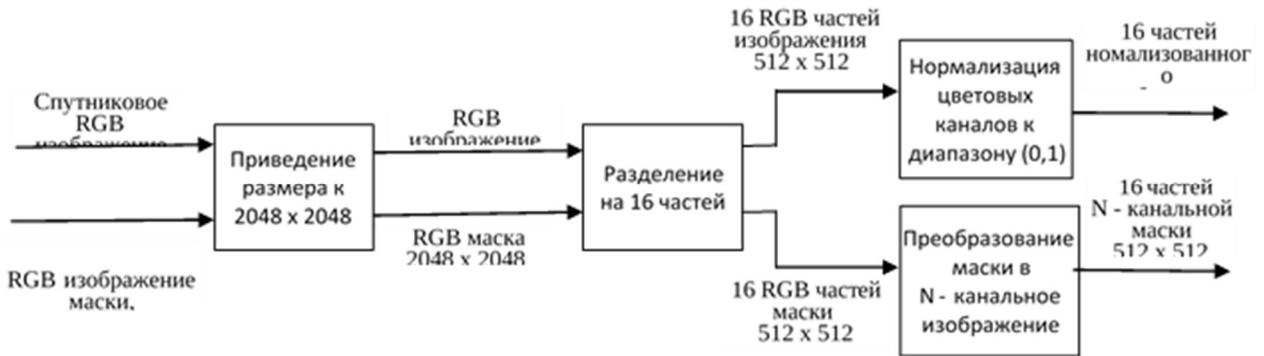


Рисунок 4.3. Алгоритм предварительной обработки изображений датасета

Все изображения из исходного набора данных подвергаются предварительной обработке в соответствии с описанной выше процедурой. В результате формируется рабочий набор данных, состоящий из 18336 фрагментов изображений и соответствующих им масок. Полученный рабочий набор разбивается случайным образом на обучающий, валидационный и тестовый наборы данных, которые составляют 60%, 20% и 20% от объема рабочего набора.

#### 4.2.2. Обучение сети

Как уже отмечалось было проведено обучение и тестирование для двух архитектур нейронных сетей – архитектуры U-Net и предложенной в данной работе архитектуры MobileNet-U-net. Для обучения обеих сетей использовались одни те же параметры.

В качестве функции потерь применялась функция, основанная на коэффициенте Дайса [119]. Этот коэффициент представляет собой метрику сходства двух множеств и вычисляется следующим образом:

$$dsc = 2 * (|x \cap y|) / (|x| + |y|) \quad (4.1)$$

где  $x$  - предсказанный класс пикселя, а  $y$  - истинный класс того же пикселя, полученный из соответствующего канала маски,  $|x|$  и  $|y|$  - количество элементов в каждом наборе, а  $|x \cap y|$  - количество совпадающих элементов в наборах. Тогда соответствующая функция потерь определяется как

$$Loss_{dsc} = 1 - dsc \quad (4.2)$$

Для итеративного обновления весов сети в процессе обучения используется алгоритм оптимизации Adam [120]. Этот алгоритм является расширением стохастического градиентного спуска. При обучении сети применялся рекомендуемый параметр скорости обучения равный  $10^{-5}$ , а также применялись алгоритмы автоматического уменьшения скорости обучения и ранней остановки обучения, если потери не снижались в течение нескольких эпох. Сеть обучалась с использованием пакетной нормализации, при этом был экспериментально выбран размер пакета равный 4.

На Рисунок 4.4 показаны графики обучения сети Unet и предлагаемой сети MobileNet-Unet в течение небольшого количества эпох. В ходе дальнейшего обучения на большем количестве эпох значения функций потерь и показатели качества сегментации изменились незначительно. Результаты обучения показывают, что предлагаемая архитектура MobileNet-Unet, позволила повысить попиксельную точность сегментации на 4,4%.

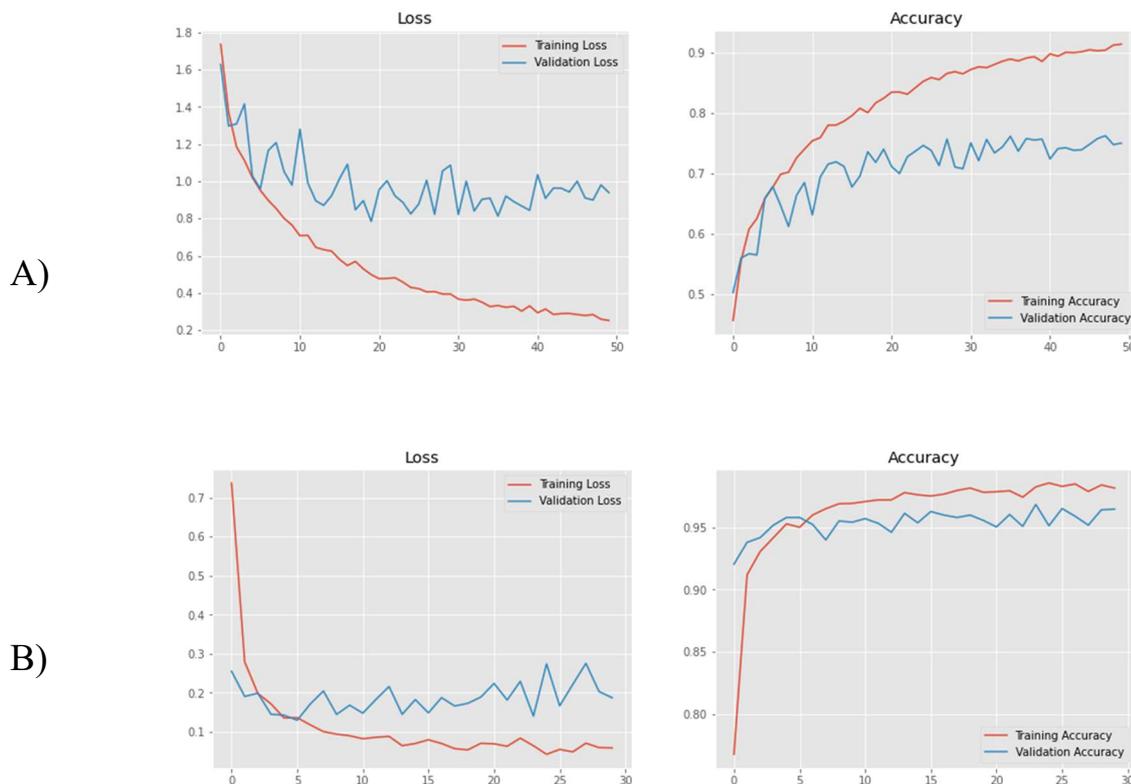


Рисунок 4.4. Графики обучения сетей Unet (A) и MobileNet-Unet (B) в зависимости от эпох обучения.

Анализ архитектуры исследуемых сетей показал, что в процессе обучения сети Unet настраивается около 31,4 миллиона параметров. В то время как, обучение предлагаемой сети MobileNet-Unet требует настройки 20,6 миллиона параметров. При этом, в случае применение обычных сверток, используемых в Unet, объем памяти, необходимый для их вычисления и хранения результатов, существенно превышает объем памяти необходимый при использовании глубинных сверток в предлагаемой сети. Таким образом, при использовании предлагаемой архитектуры, существенно снижаются требования к объему памяти, необходимому для обучения и работы нейронной сети и, следовательно, можно использовать более простые графические ускорители.

Обучение сетей проводилось с использованием графических ускорителей Nvidia с разными техническими характеристиками. Поскольку при обучении сети Unet требуется существенно больший объем памяти то использовалась видеокарта Nvidia Tesla V100 с памятью 40 Гб. Для обучения предлагаемой сети использовалась менее мощная видеокарта Nvidia GeForce RTX 3060 с памятью 4 Гб. При этом время обучения для обеих сетей оказалось примерно одинаковым.

### 4.2.3. Тестирование

Тестирование предлагаемой обученной сети MobileNet-Unet проводилось на тестовом множестве изображений. Результатом обработки каждого из тестовых изображений являются 16 частей сегментированного изображения. Каждая из этих частей представляют собой многоканальное бинарное изображение. Количество каналов равно числу сегментируемых типов земной поверхности. Для визуализации эти многоканальные изображения преобразуются в обычные RGB изображения с помощью таблицы, в которой каждому типу поверхности соответствует определенный цвет. Затем из 16 таких изображений формируется полноразмерное изображение, отражающее результат сегментации. Алгоритм визуализации результатов сегментации приведен на Рисунок 4.5. Пример

сегментации спутникового изображения из тестового набора показан на Рисунок 4.6.

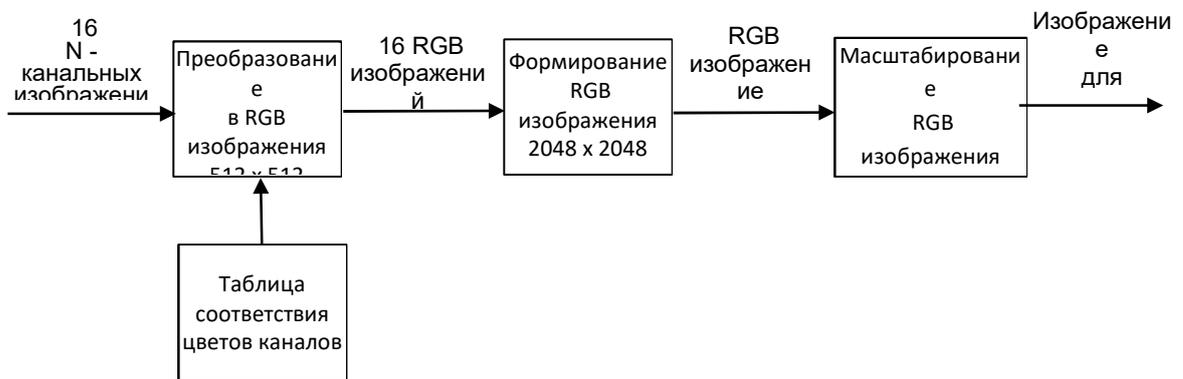


Рисунок 4.5. Алгоритм визуализации результата сегментации спутникового изображения

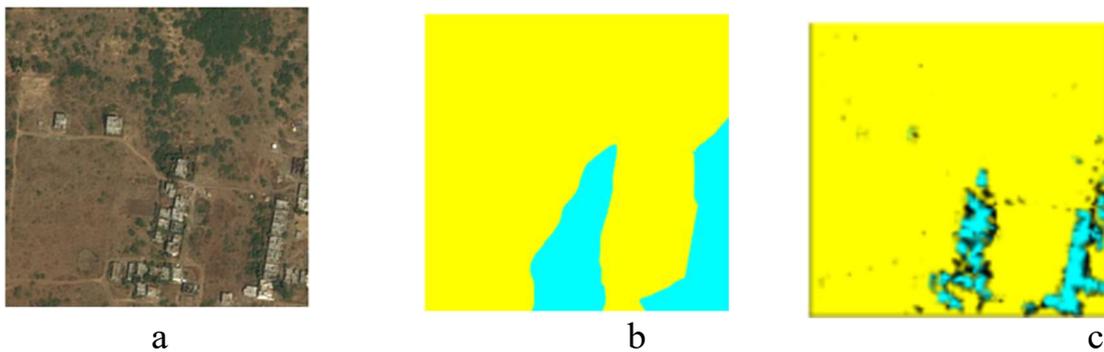


Рисунок 4.6. Пример сегментации спутникового изображения: а) исходное изображение; б) размеченная маска; с) результат сегментации. Цветовые обозначения: желтый – сельскохозяйственные земли, синий — городской район, черный — неопределенная область

При тестировании, с помощью соответствующих размеченных масок из тестового набора, определяется также попиксельная точность сегментации. Эта точность на тестовом наборе составила около 89%, что соответствует точности на валидационном наборе, использовавшемся при обучении сети.

На Рисунок 4.7 показаны результаты сегментации одного и того же спутникового изображения из тестового набора, полученные при использовании предложенной сети MobileNet-Unet, а также сети U-Net. Сравнивая эти результаты

можно заметить, что предложенная значительно лучше справляется с сегментацией областей, относящихся к сельскохозяйственным землям.

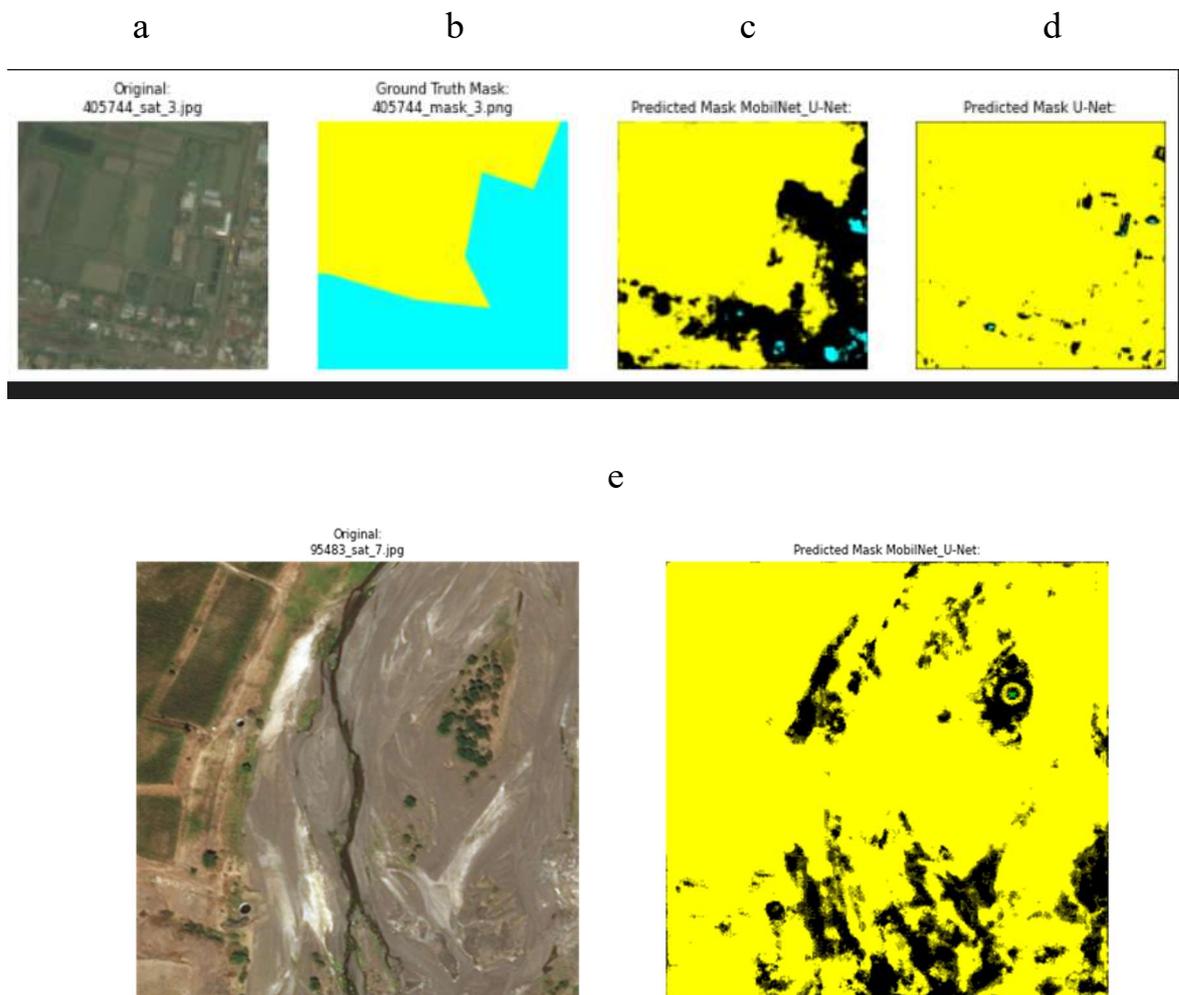


Рисунок 4.7. Примеры сегментации спутникового изображения, полученных с использованием различных архитектур нейронных сетей: а) исходное изображение; б) размеченная маска; в) результат сегментации сетью MobileNet-U-Net; д) результат сегментации сетью U-Net; е) изображение не входящее в датасет и результат его сегментации; Цветовые обозначения: желтый – сельскохозяйственные земли, синий — городской район, черный — неопределенная область

### **4.3. Нейронная сеть для классификации сельскохозяйственных культур**

После того, как автокоррекция сделана, необходимо определить состояние земли и сельскохозяйственной продукции для контроля сельскохозяйственных угодий. Индексы VI и нейронная сеть использовались для анализа сельскохозяйственных территорий и определения сельскохозяйственной продукции.

В этой работе предложенные индексы VI и архитектура сети VGG, описанные в разделах 3.6 и 3.7, применялись для семантической сегментации. Результаты его работы сравнивались с результатами сетей с другими архитектурами, широко используемыми в задачах семантической сегментации. Данное сравнение показало хорошие результаты для всех нейронных сетей, но основным требованием при выборе сети было использование меньшего количества вычислительных ресурсов.

#### **4.3.1. Датасет и предварительная обработка**

Для обучения сетей использовался предварительно обученный набор картографических данных Cropland Mapping [121], наполненный изображениями, связанными с сельскохозяйственными площадями и типами сельскохозяйственных культур. Всего в коллекции содержится 800 спутниковых снимков высокого разрешения, коллекция разделена на 5 классов, каждый из которых представлен 160 снимками и состоит из 4-канальных изображений. Помимо самих изображений, он содержит маски, указывающие вид сельскохозяйственной продукции для каждого пикселя соответствующего изображения. Набор данных включает в себя следующие типы: сельскохозяйственные угодья, пастбища, лесные угодья и типы сельскохозяйственных культур. Другие типы, не включенные в этот список, отображаются как неизвестные типы.

Спутниковые снимки обычно имеют высокое качество и большой размер. На этом этапе процесс сегментации VI выполняется перед обучением нейронных сетей. Поэтому на этом этапе по возможности не следует менять размер и качество изображений. Это связано с тем, что все данные изображения должны быть извлечены с использованием индексов без потерь. После процесса сегментации все изображения адаптируются для обучения нейронной сети, т.е. изображения масштабируются до 224x224 пикселей, поскольку выбранная архитектура VGG работает с этим стандартом размера изображения.

Набор данных состоит из спутниковых RGB-изображений конкретных областей и соответствующих им масок. Каждая маска представляет собой изображение RGB. Кроме того, каждый тип урожая отображается на маске в определенных формах.

Все изображения в исходном наборе данных предварительно обрабатываются в соответствии с процедурой, описанной выше. Полученный рабочий набор случайным образом делится на наборы обучающих, проверочных и тестовых данных, которые составляют 50%, 30% и 20% рабочего набора.

#### **4.3.2. Обучение сети**

Как упоминалось выше, контроль сельскохозяйственных земель и определение типа сельскохозяйственных культур состоит из 2 этапов. Сначала был проведен процесс сегментации с использованием индекса VI спутниковых изображений. Индексы NDVI, SAVI и EVI используются для анализа качества сельскохозяйственных земель и мониторинга сельскохозяйственных территорий. Для определения индексов используются данные о спектральных диапазонах соответствующих спутниковых снимков. Информацию об индексах можно найти в разделе 3.6, а информацию о диапазонах — на Рисунке 3.25.

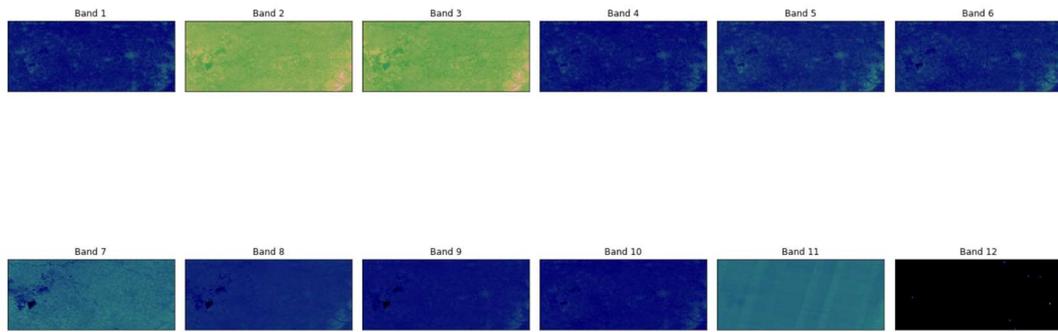


Рисунок 4.8. Визуализация спутниковых данных по диапазону

После завершения процесса сегментации все спутниковые данные подготавливаются для обучения нейронной сети. Была использована архитектура нейронной сети VGG, на основе которой изображения были уменьшены до 224x224 пикселей и создана база данных из 160 изображений для каждого класса.



Рисунок 4.9. Процесс обучения классификации сельскохозяйственных продуктов

Категориальная кросс-энтропия функции потерь использовалась для настройки нейронной сети перед обучением. Категориальная кросс-энтропия предоставляет вероятностную интерпретацию [122]. Она позволяет модели выводить вероятности каждого класса. Для двух дискретных случайных переменных и перекрестная энтропия определяется следующим образом:

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (4.3)$$

Это определение несимметрично.  $p$  предполагается “истинным” распределением, частично наблюдаемым, в то время как  $q$  предполагается

“неестественным” распределением, полученным из построенной статистической модели.

Алгоритм оптимизации Адама используется для итеративного обновления весов сети во время процесса обучения. Этот алгоритм является расширением стохастического градиентного спуска. Для обучения сети использовался рекомендуемый параметр скорости обучения  $10^{-3}$ . Сеть обучалась с использованием пакетной нормализации, а размер пакета 16 был выбран экспериментально.

На Рисунок 4.10. показывает график обучения сети VGG за небольшое количество циклов. В первом эксперименте можно увидеть график из 50 эпох. Результаты обучения показывают, что точность архитектуры VGG составила 0,88%.

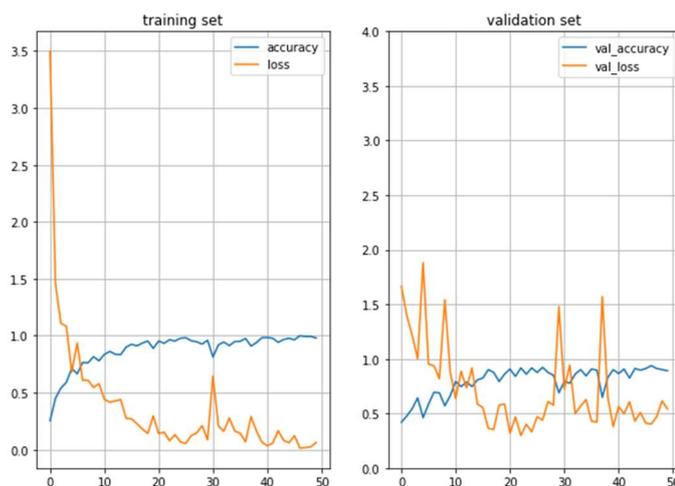


Рисунок 4.10. Экспериментальное обучение графа на основе сети VGG, состоящей из 50 эпох

Если экспериментально переобучить данные на базе архитектуры VGG на основе 100 эпох, то результат будет таким же хорошим, как и ожидалось — 0,98%. Основная причина такого результата — небольшой размер базы данных. Но увеличение объема обучения не всегда дает хорошие результаты, поскольку увеличение объема обучения может привести к переобучению. На Рисунок 4.11. показывает график обучения сети VGG за 100 циклов.

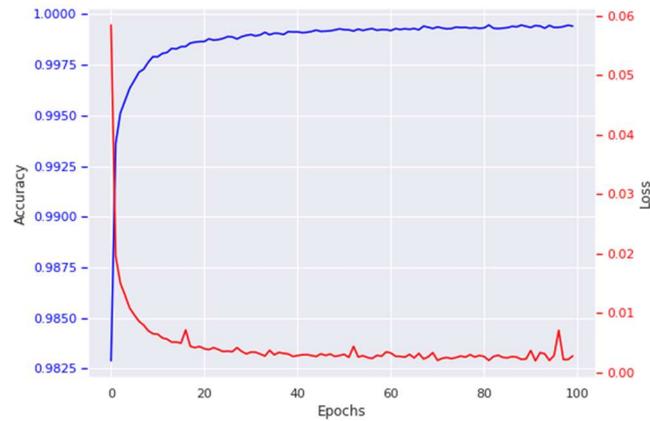


Рисунок 4.11. Экспериментальное обучение на основе сети VGG, состоящей из 100 эпох

Анализ изученной архитектуры сети показал, что в ходе обучения сети VGG было скорректировано около 2,52 млн параметров. Кроме того, при использовании традиционных 16 сверток, используемых в VGG, объем памяти, необходимый для их расчета и хранения результатов, значительно превышает объем памяти, необходимый при использовании глубоких сверток в предлагаемой сети. Таким образом, при использовании предложенной архитектуры существенно снижаются требования к памяти для обучения и работы нейронной сети, в связи с чем можно использовать более простые графические ускорители.

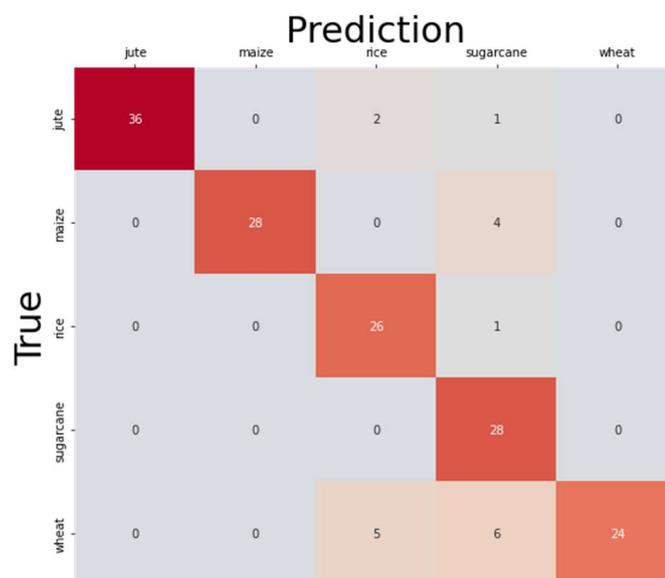


Рисунок 4.12. Результаты после обучения представлены в матрице путаницы

### 4.3.3. Тестирование

Как уже было сказано выше, процесс разделения сельскохозяйственных земель и продукции на сегменты осуществлялся двумя способами. Во-первых, для получения результатов VI было использовано более 800 наборов данных. На Рисунке 4.13 показано RGB-изображение, полученное из Ферганской области.

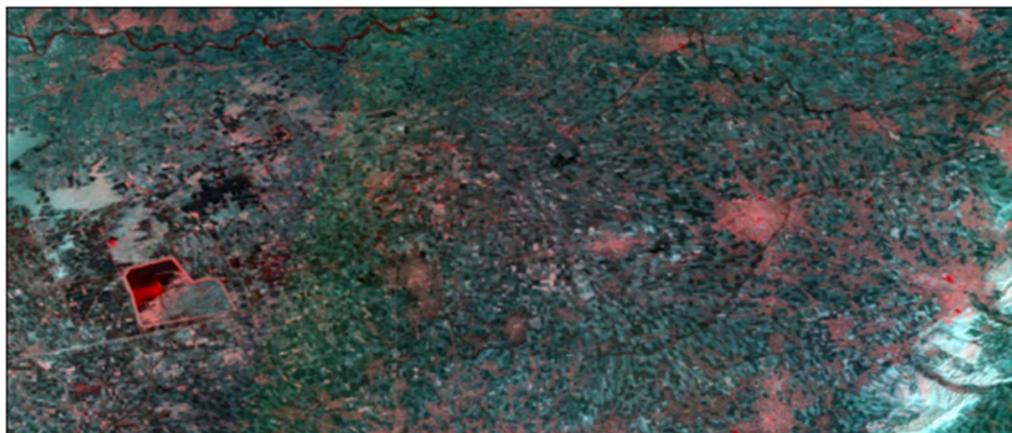


Рисунок 4.13. Составное изображение RGB с применением растягивания

На следующем этапе можно посмотреть результаты индексов NDVI и SAVI. Информация об этих индексах приведена в разделе 2.3. Следует отметить, что NDVI используется для определения сельскохозяйственной площади, а индекс SAVI контролирует качество сельскохозяйственных земель на основе анализа. На Рисунок 4.14 показаны результаты анализа на основе индекса NDVI, а на Рисунок 4.15 — результаты анализа на основе индекса SAVI.

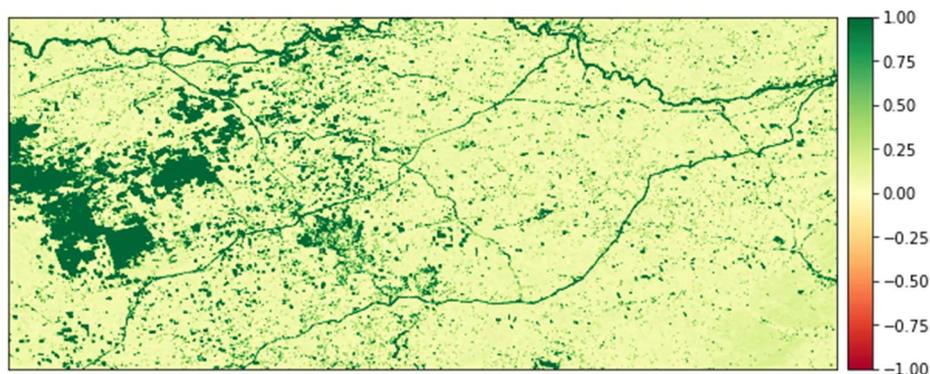


Рисунок 4.14. Пример сегментации спутниковых изображений на основе индекса NDVI

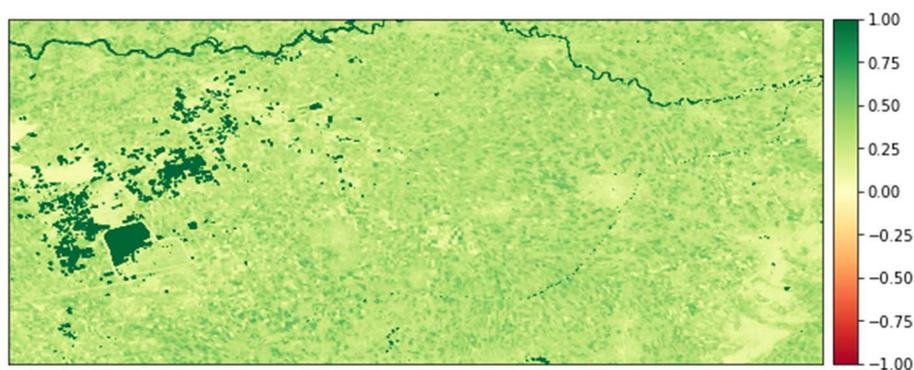


Рисунок 4.15. Пример сегментации спутниковых изображений на основе индекса SAVI

После анализа индекса VI все данные подготавливаются для обучения в нейронной сети. Обучение нейронной сети помогает идентифицировать сельскохозяйственную продукцию. В ходе теста также определяется точность (ассигасу) сегментации с использованием соответствующих помеченных масок в тестовом наборе. Эта точность на тестовом наборе составила около 88%, что аналогично точности проверочного набора, используемого для обучения сети.

На Рисунок 4.16 представлена классификация сельскохозяйственной продукции по индексам. Снимок сделан со спутника, качество изображения высокое, оно снято со среднего расстояния.

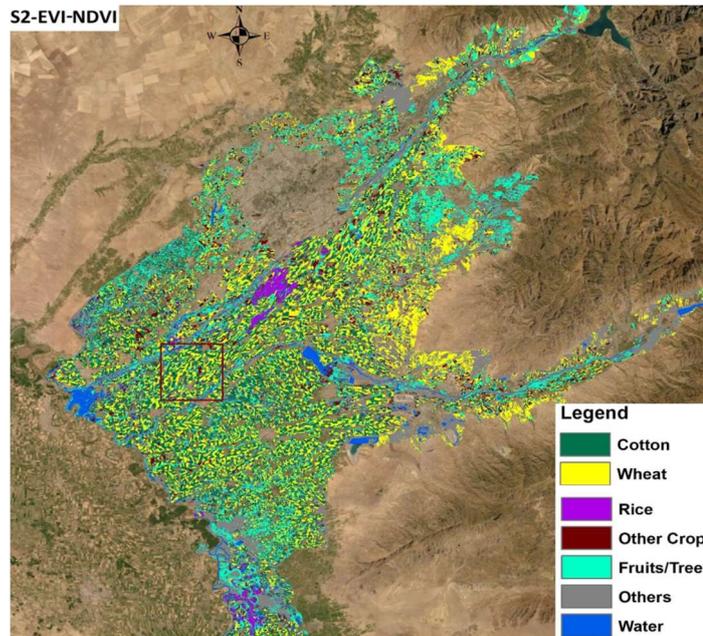


Рисунок 4.16. Результат классификации сельскохозяйственной продукции по индексам EVI и NDVI для Ташкентской области. Исходное изображение получено со спутника Sentinel 2

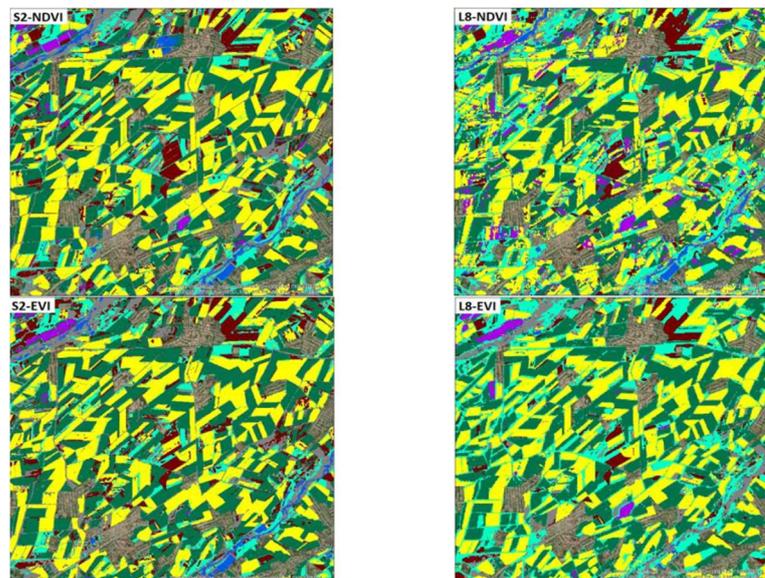


Рисунок 4.17. Результат классификации сельскохозяйственной продукции по индексам EVI и NDVI для части Ташкентской области. Цветовые обозначения: желтый – пшеница, синий — вода, зеленый — хлопок, фиолетовый – рис, красный - прочие культуры

На Рисунок 4.18 показан результат классификации сельскохозяйственной продукции для всей Ташкентской области, составленный из обработанных изображений ее частей.

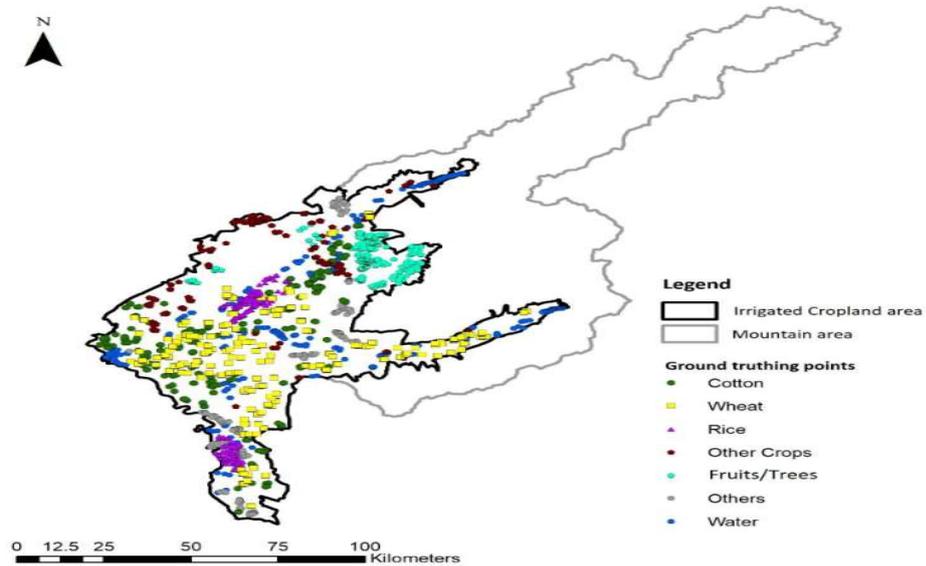


Рисунок 4.18. Результат классификации сельскохозяйственной продукции для всей Ташкентской области, полученный на базе индексов EVI и NDVI

## Выводы к главе 4

1. Для атмосферной коррекции проведено экспериментальное исследование предложенного метода на основе архитектуры нейронной сети кодер - декодер. Этот новый метод, позволяет избежать использования программ интерактивной коррекции. Точность этого метода составил 90,5% по сравнению с результатом интерактивной программы (Sen2Core), что показывает его адекватность. Предлагаемый метод позволяет автоматизировать процесс атмосферной коррекции «сырых» спутниковых изображений и отказаться от использования интерактивных программ, требующих участия пользователя.
2. Для классификации сельскохозяйственных территорий и продуктов использовались два разных метода. Во-первых, индексы VI использовались для определения состояния и продуктивности сельскохозяйственных земель. Во-вторых, данные, полученные на основе индексов VI, были использованы для обучения нейронной сети с модифицированной архитектурой VGG. В результате удалось определить виды сельскохозяйственной продукции, культивируемых на исследуемой территории. Точность результата оказалась равной 88%.
3. Экспериментально исследован новый метод на основе нейронных сетей для отслеживания городской и сельской местности, обнаружения объектов и отслеживания изменений в городах. Для этого использовались архитектуры кодера-декодера U-Net и MobileNet. На первом этапе данные были обучены с использованием архитектуры U-Net. Точность результата, полученного от применения архитектуры U-Net, составила 89 %. Для повышения точности, в рамках архитектуры U-Net ее кодирующая часть заменена кодирующей частью на базе архитектуры сети MobileNet. Проведенное экспериментальное исследование показало улучшение точности сегментации на 4,4%.

## ЗАКЛЮЧЕНИЕ

Представленная диссертация представляет собой исследование, посвященное разработке методов и инструментов обработки данных, полученных со спутников, с целью проведения мониторинга обширных территорий. Основные научные и прикладные результаты данной работы можно описать следующим образом:

1. Разработан и реализован метод атмосферной коррекции для обработки спутниковых изображений. Этот метод позволяет получать спутниковые снимки, на которые не влияют свойства атмосферы, а также дает возможность унифицировать изображения, получаемые с разных спутников. При этом возможно, без привлечения существующих интерактивных программ, осуществлять автоматическую атмосферную коррекцию снимков, для которых отсутствует она отсутствует.
2. Предложен и реализован метод, основанный на модификации архитектуры нейронной сети глубокого обучения, который позволяет сегментировать и идентифицировать объекты на территориях, включая городские и сельскохозяйственные районы. Метод позволяет повысить точность результатов и существенно снизить требования к вычислительным ресурсам, необходимых при решении подобных задач.
3. Предложены и реализованы методы оценки состояния сельскохозяйственных зон и классификации посевов с использованием алгоритмов определения вегетационных индексов и методов глубокого обучения.
4. Проведено экспериментальное исследование всех предложенных методов, реализованных в виде соответствующего программного обеспечения. Это исследование показало повышение точности результатов обработки спутниковых снимков, по сравнению с существующими методами. Эта реализация позволила снизить требования к вычислительным ресурсам как по памяти, так и по аппаратной поддержке вычислений.

**СПИСОК ЛИТЕРАТУРЫ**

1. Grishkin V. et al. Detection Of Fertile Soils Based On Satellite Imagery Processing [Электронный ресурс] / V Grishkin, E Zhivulin, A Khokhriakova, S Karimov // Ceur Workshop Proceedings. – 2021. – P. 251-255. - Режим доступа: <https://doi.org/10.54546/mlit.2021.13.12.001> (дата обращения: 24.03.2024).
2. Grishkin V. M., Karimov S. I. Use of satellite imagery and index control to monitor and analyze the agricultural lands of Bukhara region, which is a world historical heritage [Электронный ресурс] / V Grishkin, S Karimov // AIP Conference Proceedings. – AIP Publishing, 2022. – Vol. 2432. – №. 1 - Режим доступа: <https://doi.org/10.1063/5.0089537> (дата обращения: 25.03.2024).
3. Karimov S. I. Structural strategy for the formation of remote monitoring of agricultural lands // Modern methods of applied mathematics, control theory and computer technologies (PMTUKT-2021). – 2021. – P. 59-62.
4. Karimov S. I., Karimova M. I., Grishkin V. M. General description of the reception and study of data coming through the satellite // Digital region: experience, competencies, projects. – 2020. – P. 1044-1047.
5. Grishkin V. M., Karimov S. I. U. Models and methods of data processing remote sensing // The American journal of engineering and technology. – 2021. – Vol. 3. – No. 02. - P. 67-74.
6. Grishkin V. M. et al. Comparison of multi-resource remote sensing data for vegetation indices. – 2021.
7. Karimov S.I. Machine learning methods for predicting yield using sentinel-2 satellite images // International scientific and technical conference "Advanced Information Technologies" (PIT-2022). – 2022. – P. 163-169.
8. Ashurmetova N. A. Current state and strategy for the development of the agricultural sector of the Republic of Uzbekistan // Science without borders. – 2020. – No. 2 (42). - P. 18-26.

9. Abdurakhmanov M. A., Rakhimov Ya. T. State of land resources in the Republic of Uzbekistan // Territory of Science. – 2017. – No. 4. - P. 74-77.
10. Kozoderov V.V., Dmitriev E.V. Aerospace sounding of soil and vegetation cover: models, algorithmic and software, ground-based validation // Research of the Earth from Space. – 2010. – №. 1. – P. 69-86.
11. Kazyak E. V., Khrushcheva E. O., Lukashik A. A. Analysis of the seasonal dynamics of the spectral reflectance of agricultural crops using ground-based and satellite data to improve remote monitoring of their crops: report on research work (final) / BSU; scientific supervisor EV Kazyak. – 2017.
12. Zarubin O. A., Zhatkina I. A., Kopinov A. V. On the issue of using Earth remote sensing data to assess the state of vegetation // Scientific research of modern scientists. – 2016. – P. 322-332.
13. Várnai T., Marshak A. MODIS observations of enhanced clear sky reflectance near clouds //Geophysical Research Letters. – 2009. – Vol. 36. – №. 6.
14. Shrestha B., O'Hara C., Mali P. Multi-sensor & temporal data fusion for cloud-free vegetation index composites //Sensor and Data Fusion. – IntechOpen, 2009.
15. Bykov V.L. et al. Application of remote sensing data for information support of the precision farming system // Bulletin of the Omsk State Agrarian University. – 2016. – No. 1 (21). – P. 146-154.
16. Xue J. et al. Significant remote sensing vegetation indicators: A review of developments and applications //Journal of sensors. – 2017. – Vol. 2017.
17. Kurbatova E. A., Denisova E. S. Space monitoring of agricultural land // Current problems of land management and cadastres at the present stage. - 2015. - P. 62-65.
18. Roberts D. A. et al. Hyperspectral vegetation indices //Hyperspectral indices and image classifications for agriculture and vegetation. – CRC press, 2018. – P. 3-26.
19. Nezamov V.I., Mamontova S.A., Bondareva D.V. Study of the possibilities of monitoring floods by space images //Modern problems of land management, cadastres, environmental management and improving labor safety in the agro-industrial complex. - 2021. - P. 122-124.

20. Goodin D. G., Anibas K. L., Bezymennyi M. Mapping land cover and land use from object-based classification: An example from a complex agricultural landscape //International Journal of Remote Sensing. – 2015. – Vol. 36. – No. 18. – P. 4702-4723.
21. Gómez C., White J. C., Wulder M. A. Optical remotely sensed time series data for land cover classification: A review //ISPRS Journal of photogrammetry and Remote Sensing. – 2016. – Vol. 116. – P. 55-72.
22. Hill M. J., Donald G. E. Estimating spatio-temporal patterns of agricultural productivity in fragmented landscapes using AVHRR NDVI time series //Remote sensing of environment. – 2003. – Vol. 84. – No. 3. - P. 367-384.
23. Savin I. Yu., Lupyan E. A., Bartalev S. A. Operational satellite monitoring of the state of agricultural crops in Russia // Geomatics. – 2011. – №. 2. - P. 69-76.
24. Gao F. et al. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery //Remote Sensing of Environment. – 2017. – Vol. 188. – P. 9-25.
25. Voronina P. V., Mamash E. A. Classification of thematic problems of agricultural monitoring using MODIS remote sensing data //Computational technologies. – 2014. – Vol. 19. – No. 3. - P. 76-102.
26. Gray J. et al. Mapping Asian cropping intensity with MODIS //IEEE Journal of selected topics in applied earth observations and remote sensing. – 2014. – Vol. 7. – No. 8. - P. 3373-3379.
27. Gumma M. K. et al. Mapping rice areas of South Asia using MODIS multitemporal data //Journal of applied remote sensing. – 2011. – Vol. 5. – No. 1. - P. 053547-053547-26.
28. Yue-peng P., Shu-ying Z. Crop identification based on MODIS NDVI time-series data and phenological characteristics // Journal of Natural Resources. – 2016. – Vol. 31. – No. 3. - P. 503-513.
29. Yang W., Zhang S. Monitoring vegetation phenology using modis time-series data //2012 2nd International Conference on Remote Sensing, Environment and Transportation Engineering. - IEEE, 2012. - P. 1-4.

30. Bulgakov D. S. et al. The application of soil-agroclimatic index for assessing the agronomic potential of arable lands in the forest-steppe zone of Russia //Eurasian Soil Science. – 2018. – Vol. 51. – P. 448-459.
31. Milanova E. Land use/cover change in Russia within the context of global challenges // Rom. J. Geogr. – 2012. – Vol. 56. – No. 2. – P. 105.
32. Movchan D. et al. Uncertainty analysis in crop productivity and remote estimation for agricultural risk assessment //Vulnerability, Uncertainty, and Risk: Quantification, Mitigation, and Management. – 2014. – P. 1008-1015.
33. Barbotkina E. et al. Digital approaches in agriculture crop monitoring //IOP Conference Series: Earth and Environmental Science. – IOP Publishing, 2021. – Vol. 937. – No. 3. - P. 032098.
34. Movchan D. et al. Uncertainty analysis in crop productivity and remote estimation for agricultural risk assessment //Vulnerability, Uncertainty, and Risk: Quantification, Mitigation, and Management. – 2014. – P. 1008-1015.
35. Lysenko S. A. Crop yield forecasting based on the satellite monitoring of carbon dynamics in terrestrial ecosystems // Earth Research from Space. – 2019. – No. 4. - P. 48-59.
36. Bhatta B. Analysis of urban growth and sprawl from remote sensing data. – Springer Science & Business Media, 2010.
37. Bhatta B., Saraswati S., Bandyopadhyay D. Quantifying the degree-of-freedom, degree-of-sprawl, and degree-of-goodness of urban growth from remote sensing data //Applied Geography. – 2010. – Vol. 30. – No. 1. - P. 96-111.
38. Li C., Thinh N. X. Investigation and comparison of land-cover change patterns in Xuzhou city, China, and Dortmund city region, Germany, using multitemporal Landsat images // Journal of Applied Remote Sensing. – 2013. – Vol. 7. – No. 1. - P. 073458-073458.
39. Deng J. S. et al. Spatio-temporal dynamics and evolution of land use change and landscape pattern in response to rapid urbanization //Landscape and urban planning. – 2009. – Vol. 92. – No. 3-4. - P. 187-198.

40. Braimoh A. K., Onishi T. Spatial determinants of urban land use change in Lagos, Nigeria // *Land use policy*. – 2007. – Vol. 24. – No. 2. - P. 502-515.
41. Dewan A. M., Yamaguchi Y. Land use and land cover change in Greater Dhaka, Bangladesh: Using remote sensing to promote sustainable urbanization // *Applied geography*. – 2009. – Vol. 29. – No. 3. - P. 390-401.
42. Wu J. et al. Quantifying spatiotemporal patterns of urbanization: The case of the two fastest growing metropolitan regions in the United States // *Ecological Complexity*. – 2011. – Vol. 8. – No. 1. - P. 1-8.
43. Liu X., Lathrop Jr R. G. Urban change detection based on an artificial neural network // *International Journal of Remote Sensing*. – 2002. – Vol. 23. – No. 12. – P. 2513-2518.
44. Barron O. V., Barr A. D., Donn M. J. Effect of urbanization on the water balance of a catchment with shallow groundwater // *Journal of Hydrology*. – 2013. – Vol. 485. – P. 162-176.
45. Seto K. C., Fragkias M. Quantifying spatiotemporal patterns of urban land-use change in four cities of China with time series landscape metrics // *Landscape ecology*. – 2005. – Vol. 20. – P. 871-888.
46. Hamidi S., Ewing R. A longitudinal study of changes in urban sprawl between 2000 and 2010 in the United States // *Landscape and urban planning*. – 2014. – Vol. 128. – P. 72-82.
47. Goetz A. Suburban sprawl or urban centers: Tensions and contradictions of smart growth approaches in Denver, Colorado // *Urban Studies*. – 2013. – Vol. 50. – No. 11. – P. 2178-2195.
48. Siedentop S., Fina S. Urban sprawl beyond growth: the effect of demographic change on infrastructure costs // *Flux*. – 2010. – No. 1. - P. 90-100.
49. Aguilera F., Valenzuela L. M., Botequilha-Leitão A. Landscape metrics in the analysis of urban land use patterns: A case study in a Spanish metropolitan area // *Landscape and Urban Planning*. – 2011. – Vol. 99. – No. 3-4. - P. 226-238.
50. Hasse J. E., Lathrop R. G. Land resource impact indicators of urban sprawl // *Applied geography*. – 2003. – Vol. 23. – No. 2-3. - P. 159-175.

51. Aguilera F., Valenzuela L. M., Botequilha-Leitão A. Landscape metrics in the analysis of urban land use patterns: A case study in a Spanish metropolitan area // *Landscape and Urban Planning*. – 2011. – Vol. 99. – No. 3-4. - P. 226-238.
52. Leh M., Bajwa S., Chaubey I. Impact of land use change on erosion risk: an integrated remote sensing, geographic information system and modeling methodology [Электронный ресурс] // *Land Degradation & Development*. – 2013. – Т. 24. – No. 5. - P. 409-421 - Режим доступа: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/ldr.1137> (дата обращения: 29.03.2024).
53. Narumalani S., Mishra D. R., Rothwell R. G. Change detection and landscape metrics for inferring anthropogenic processes in the greater EFMO area // *Remote sensing of environment*. – 2004. – Vol. 91. – No. 3-4. - P. 478-489.
54. Burger W., Burge M. J. Digital image processing: An algorithmic introduction. [Электронный ресурс] – Springer Nature, 2022 - Режим доступа: [https://books.google.com/books?hl=ru&lr=&id=\\_kB9EAAAQBAJ&oi=fnd&pg=PR5&dq=Introductory+Digital+Image+Processing&ots=XpCrt\\_kJSI&sig=svZtYojekB5u-UYTOSsXHFCqFJw](https://books.google.com/books?hl=ru&lr=&id=_kB9EAAAQBAJ&oi=fnd&pg=PR5&dq=Introductory+Digital+Image+Processing&ots=XpCrt_kJSI&sig=svZtYojekB5u-UYTOSsXHFCqFJw) (дата обращения: 29.03.2024).
55. Franklin S. E., Wulder M. A. Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas // *Progress in Physical Geography*. – 2002. – Vol. 26. – No. 2. - P. 173-205.
56. Alberti M., Marzluff J. M. Ecological resilience in urban ecosystems: Linking urban patterns to human and ecological functions // *Urban ecosystems*. – 2004. – Vol. 7. – P. 241-265.
57. Gavrilidis A. A. et al. Urban landscape quality index—planning tool for urban evaluating landscapes and improving the quality of life // *Procedia Environmental Sciences*. – 2016. – Vol. 32. – P. 155-167.
58. Mörtberg U. M., Balfors B., Knol W. C. Landscape ecological assessment: A tool for integrating biodiversity issues in strategic environmental assessment and planning // *Journal of environmental management*. – 2007. – Vol. 82. – No. 4. - P. 457-470.

59. Li Y. et al. Landscape effects of environmental impact on bay-area wetlands under rapid urban expansion and development policy: A case study of Lianyungang, China //Landscape and urban Planning. – 2010. – Vol. 94. – No. 3-4. - P. 218-227.
60. Bino G. et al. Accurate prediction of bird species richness patterns in an urban environment using Landsat-derived NDVI and spectral unmixing //International Journal of Remote Sensing. – 2008. – Vol. 29. – No. 13. - P. 3675-3700.
61. Medeiros A. et al. Research trends on integrative landscape assessment using indicators—A systematic review //Ecological Indicators. – 2021. – Vol. 129. – P. 107815.
62. Vermaat J. E. et al. Differentiating the effects of climate and land use change on European biodiversity: A scenario analysis //Ambio. – 2017. – Vol. 46. – P. 277-290.
63. Halada L. et al. The European biodiversity observation network-EBONE [Электронный ресурс]. – 2009 - Режим доступа: [https://nora.nerc.ac.uk/id/eprint/5738/1/Halada\\_et\\_al\\_e-e-envi2009\\_final.pdf](https://nora.nerc.ac.uk/id/eprint/5738/1/Halada_et_al_e-e-envi2009_final.pdf) (дата обращения: 29.03.2024).
64. Seto K. C., Güneralp B., Hutyra L. R. Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools // Proceedings of the National Academy of Sciences. – 2012. – Vol. 109. – No. 40. – P. 16083-16088.
65. Zavatiero L. et al. Towards the identification and mapping of traditional agricultural landscapes at the national scale: An inventory approach from Italy //Landscape Research. – 2021. – Vol. 46. – No. 7. - P. 945-958.
66. Güneralp B., Seto K. C. Futures of global urban expansion: uncertainties and implications for biodiversity conservation //Environmental Research Letters. – 2013. – Vol. 8. – No. 1. - P. 014025.
67. Ban Y., Yousif O., Hu H. 18 Fusion of SAR and Optical Data for Urban Land Cover Mapping and Change Detection //Glob. Urban Monit. Assess. Earth Obs. – 2014. – P. 353.
68. Bhabatosh C. et al. Digital image processing and analysis [Электронный ресурс]. – PHI Learning Pvt. Ltd., 2011 - Режим доступа:

[https://books.google.com/books?hl=ru&lr=&id=3xGLVyEc\\_SIC&oi=fnd&pg=PR15&dq=Digital+image+processing+and+analysis&ots=wD3AXeZJVf&sig=6CvKdusd1x5DJpl\\_yZZBhRyvzoU](https://books.google.com/books?hl=ru&lr=&id=3xGLVyEc_SIC&oi=fnd&pg=PR15&dq=Digital+image+processing+and+analysis&ots=wD3AXeZJVf&sig=6CvKdusd1x5DJpl_yZZBhRyvzoU) (дата обращения: 29.03.2024).

69. Lee K. H., Yum J. M. A review on atmospheric correction technique using satellite remote sensing //Korean Journal of Remote Sensing. – 2019. – Vol. 35. – No. 6\_1. – P. 1011-1030.
70. Peijun D. U. et al. Monitoring urban land cover and vegetation change by multi-temporal remote sensing information // Mining Science and Technology (China). – 2010. – Vol. 20. – No. 6. - P. 922-932.
71. Jebur M. N. et al. Per-pixel and object-oriented classification methods for mapping urban land cover extraction using SPOT 5 imagery // Geocarto International. – 2014. – Vol. 29. – No. 7. - P. 792-806.
72. Cleve C. et al. Classification of the wildland–urban interface: A comparison of pixel-and object-based classifications using high-resolution aerial photography //Computers, Environment and Urban Systems. – 2008. – Vol. 32. – No. 4. - P. 317-326.
73. Blaschke T. Object based image analysis for remote sensing //ISPRS journal of photogrammetry and remote sensing. – 2010. – Vol. 65. – No. 1. – P. 2-16.
74. Ban Y., Jacob A. Object-based fusion of multitemporal multiangle ENVISAT ASAR and HJ-1B multispectral data for urban land-cover mapping //IEEE transactions on geoscience and remote sensing. – 2013. – Vol. 51. – No. 4. – P. 1998-2006.
75. Jacquin A., Misakova L., Gay M. A hybrid object-based classification approach for mapping urban sprawl in periurban environment //Landscape and urban planning. – 2008. – Vol. 84. – No. 2. - P. 152-165.
76. Ban Y., Hu H., Rangel I. M. Fusion of Quickbird MS and RADARSAT SAR data for urban land-cover mapping: Object-based and knowledge-based approach // International Journal of Remote Sensing. – 2010. – Vol. 31. – No. 6. - P. 1391-1410.

77. Li C. et al. Comparison of classification algorithms and training sample sizes in urban land classification with Landsat thematic mapper imagery //Remote sensing. – 2014. – Vol. 6. – No. 2. - P. 964-983.
78. Radoux J., Defourny P. A quantitative assessment of boundaries in automated forest stand delineation using very high resolution imagery //Remote Sensing of Environment. – 2007. – Vol. 110. – No. 4. - P. 468-475.
79. Tiede D. et al. Adapting, splitting and merging cadastral boundaries according to homogenous LULC types derived from SPOT 5 data [Электронный ресурс] //Proc. of the ISPRS Workshop Photogr. Image Analysis, Munich. – 2007 - Режим доступа: [https://www.isprs.org/proceedings/XXXVI/3-W49/PartA/papers/PIA07\\_Tiede\\_et\\_al.pdf](https://www.isprs.org/proceedings/XXXVI/3-W49/PartA/papers/PIA07_Tiede_et_al.pdf) (дата обращения: 29.03.2024).
80. Su W. et al. Object oriented implementation monitoring method of zone feature in land consolidation engineering using SPOT 5 imagery //WSEAS Transactions on Computers. – 2008. – Vol. 7. – No. 7. - P. 847-856.
81. Yu W. et al. A new approach for land cover classification and change analysis: Integrating backdating and an object-based method //Remote Sensing of Environment. – 2016. – Vol. 177. – P. 37-47.
82. Lisita A., Sano E. E., Durieux L. Identifying potential areas of Cannabis sativa plantations using object-based image analysis of SPOT-5 satellite data //International journal of remote sensing. – 2013. – Vol. 34. – No. 15. – P. 5409-5428.
83. Dimitrakopoulos K. et al. Land cover/use mapping using object based classification of SPOT imagery //Remote Sensing for Science, Education, and Natural and Cultural Heritage. – 2010. – P. 263-271.
84. Kamal M., Phinn S., Johansen K. Object-based approach for multi-scale mangrove composition mapping using multi-resolution image datasets //Remote Sensing. – 2015. – Vol. 7. – No. 4. - P. 4753-4783.
85. Boggs G. S. Assessment of SPOT 5 and QuickBird remotely sensed imagery for mapping tree cover in savannas //International journal of applied earth observation and geoinformation. – 2010. – Vol. 12. – No. 4. - P. 217-224.

86. Tehrani M. S., Pradhan B., Jebuv M. N. A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery // *Geocarto International*. – 2014. – Vol. 29. – No. 4. - P. 351-369.
87. Chen M. et al. Comparison of pixel-based and object-oriented knowledge-based classification methods using SPOT5 imagery // *WSEAS Transactions on Information Science and Applications*. – 2009. – Vol. 6. – No. 3. - P. 477-489.
88. Newman M. E., McLaren K. P., Wilson B. S. Comparing the effects of classification techniques on landscape-level assessments: pixel-based versus object-based classification // *International Journal of Remote Sensing*. – 2011. – Vol. 32. – No. 14. – P. 4055-4073.
89. Jönsson C. Ny metod för kontinuerlig naturtypskartering av skyddade områden (KNAS) [Электронный ресурс]. – 2009 - Режим доступа: <https://www.diva-portal.org/smash/get/diva2:223916/FULLTEXT02> (дата обращения: 29.03.2024).
90. Abdulateef S. K., Salman M. D. A Comprehensive Review of Image Segmentation Techniques // *Iraqi Journal for Electrical & Electronic Engineering*. – 2021. – Vol. 17. – No. 2.
91. Soofi A. A., Awan A. Classification techniques in machine learning: applications and issues // *J. Basic Appl. Sci.* – 2017. – Vol. 13. – No. 1. - P. 459-465.
92. Andrew T. Let's grok deep learning [Электронный ресурс]. – "Publishing house" "Peter", 2019 - Режим доступа: <https://books.google.com/books?hl=ru&lr=&id=3K6tDwAAQBAJ&oi=fnd&pg=PA12&dq=%D0%93%D1%80%D0%BE%D0%BA%D0%B0%D0%B5%D0%BC+%D0%B3%D0%BB%D1%83%D0%B1%D0%BE%D0%BA%D0%BE%D0%B5+%D0%BE%D0%B1%D1%83%D1%87%D0%B5%D0%BD%D0%B8%D0%B5&ots=hlrJRasEPB&sig=IiPRZQVPikUrsvGRHwSbqbHrHh0> (дата обращения: 29.03.2024).

93. Maggiori E. et al. High-resolution aerial image labeling with convolutional neural networks //IEEE Transactions on Geoscience and Remote Sensing. – 2017. – Vol. 55. – No. 12. - P. 7092-7103.
94. Barthakur M., Sarma K. K. Semantic segmentation using K-means clustering and deep learning in satellite image //2019 2nd International Conference on Innovations in Electronics, Signal Processing and Communication (IESC). - IEEE, 2019. - P. 192-196.
95. Sze V. et al. Efficient processing of deep neural networks: A tutorial and survey //Proceedings of the IEEE. – 2017. – Vol. 105. – No. 12. – P. 2295-2329.
96. Samek W. et al. Explaining deep neural networks and beyond: A review of methods and applications //Proceedings of the IEEE. – 2021. – Vol. 109. – No. 3. - P. 247-278.
97. Rawat W., Wang Z. Deep convolutional neural networks for image classification: A comprehensive review //Neural computation. – 2017. – Vol. 29. – No. 9. – P. 2352-2449
98. Deepan P., Sudha L. R. Object classification of remote sensing image using deep convolutional neural network //The cognitive approach in cloud computing and internet of things technologies for surveillance tracking systems. - Academic Press, 2020. - P. 107-120.
99. Kroupi E. et al. Deep convolutional neural networks for land-cover classification with Sentinel-2 images //Journal of Applied Remote Sensing. – 2019. – Vol. 13. – No. 2. - P. 024525-024525.
100. Liu C. C. et al. Clouds classification from Sentinel-2 imagery with deep residual learning and semantic image segmentation //Remote Sensing. – 2019. – Vol. 11. – No. 2. – P. 119.
101. Shamsolmoali P. et al. A novel deep structure U-Net for sea-land segmentation in remote sensing images //IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. – 2019. – Vol. 12. – No. 9. - P. 3219-3232.
102. Khryashchev V. V. et al. Optimization of convolutional neural network for object recognition on satellite images //2018Systems of Signal Synchronization,

- Generating and Processing in Telecommunications (SYNCHROINFO). - IEEE, 2018. - P. 1-5.
103. Aitken K. et al. Understanding how encoder-decoder architectures attend //Advances in Neural Information Processing Systems. – 2021. – Vol. 34. – P. 22184-22195.
104. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2015. – P. 3431-3440.
105. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation //Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18. - Springer International Publishing, 2015. - P. 234-241.
106. Howard A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [Электронный ресурс] //arXiv preprint arXiv:1704.04861, 2017 - Режим доступа: <https://arxiv.org/pdf/1704.04861.pdf%EF%BC%89> (дата обращения: 08.04.2024).
107. Zeiler M. D., Taylor G. W., Fergus R. Adaptive deconvolutional networks for mid and high level feature learning //2011 international conference on computer vision. – IEEE, 2011. – P. 2018-2025.
108. He K. et al. Identity mappings in deep residual networks //Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14. – Springer International Publishing, 2016. – P. 630-645.
109. Szegedy C. et al. Rethinking the inception architecture for computer vision //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – P. 2818-2826.

110. Tan M., Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks //International conference on machine learning. - PMLR, 2019. - P. 6105-6114.
111. Sinha D., El-Sharkawy M. Thin mobilenet: An enhanced mobilenet architecture //2019 IEEE 10th annual ubiquitous computing, electronics & mobile communication conference (UEMCON). - IEEE, 2019. - P. 0280-0285.
112. Saidazimova G. S. Uzbekistan //Handbook of Research on Asian Entrepreneurship. – Edward Elgar Publishing, 2009.
113. Erdanaev E. et al. Short Review of Climate and Land Use change Impact on Land Degradation in Tashkent Province //International Journal of Geoinformatics. – 2015.
114. Erdanaev E., Kappas M., Wyss D. Irrigated crop types mapping in Tashkent province of Uzbekistan with remote sensing-based classification methods //Sensors. – 2022. – Vol. 22. – No. 15. – P. 5683.
115. Mascarenhas S., Agarwal M. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification //2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON). – IEEE, 2021. – Vol. 1. – P. 96-99.
116. Ivanov S.V. Metrics for classification of machine learning problems // Current problems and prospects for economic development. – 2020. – P. 173-174.
117. Bagaev S. M., Medvedeva E. V. Experimental assessment of the accuracy of multi-class segmentation of objects on satellite images based on a modified convolutional neural network U-net //MODERN PROBLEMS OF REMOTE SENSING OF THE EARTH FROM SPACE Founders: Institute of Space Research of the Russian Academy of Sciences. – 2021. – T. 18. – No. 6. - P. 35-45.
118. Demir I. et al. Deepglobe 2018: A challenge to parse the earth through satellite images //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. – 2018. – P. 172-181.

119. Janocha K., Czarnecki W. M. On loss functions for deep neural networks in classification [Электронный ресурс] //arXiv preprint arXiv:1702.05659. 2017 - Режим доступа: <https://arxiv.org/pdf/1702.05659.pdf> (дата обращения: 16.04.2024).
120. Zhang Z. Improved adam optimizer for deep neural networks //2018 IEEE/ACM 26th international symposium on quality of service (IWQoS). – Ieee, 2018. – P. 1-2.
121. Crop mapping using fused optical-radar data set [Электронный ресурс] // UCI Machine Learning Repository, 2020 - Режим доступа: <https://doi.org/10.24432/C5G89D> (дата обращения: 16.04.2024).
122. Zhang Z., Sabuncu M. Generalized cross entropy loss for training deep neural networks with noisy labels //Advances in neural information processing systems. – 2018. – Vol. 31.
123. Свидетельство о государственной регистрации программы для ЭВМ № RU2023664858 Российская Федерация // Программа для распознавания и сегментации объектов на спутниковых снимках» (SatObj) // № 2023663505: заявл. 28.06.2023: опубл. 10.07.2023 Бюл. № 7 // В. М. Гришкин, С. И. Каримов // Федеральное государственное бюджетное образовательное учреждение высшего образования "Санкт-Петербургский государственный университет" (СПбГУ).
124. Гришкин В.М., Каримов С.И. Глубокая нейронная сеть для семантическая сегментация спутниковых изображений // Научные технологии в космических исследованиях Земли, 2024, Т.16, № 3, С. 12-17.
125. Grishkin V. M., Karimov S. I. Atmospheric correction of satellite images using a neural network // Physics of Particles and Nuclei, 2024, Vol. 55, No. 3, P. 545–547.

## ПРИЛОЖЕНИЕ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



## СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2023664858

**«Программа для распознавания и сегментации объектов  
на спутниковых снимках» (SatObj)**

Правообладатель: *федеральное государственное бюджетное  
образовательное учреждение высшего образования  
"Санкт-Петербургский государственный университет"  
(СПбГУ) (RU)*

Авторы: *Гришкин Валерий Михайлович (RU), Каримов  
Сардор Илхом угли (UZ)*

Заявка № 2023663505

Дата поступления 28 июня 2023 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 10 июля 2023 г.



Руководитель Федеральной службы  
по интеллектуальной собственности

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



RU2023664858

ФЕДЕРАЛЬНАЯ СЛУЖБА  
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ  
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства): 2023664858 Дата регистрации: 10.07.2023 Номер и дата поступления заявки: 2023663505 28.06.2023 Дата публикации и номер бюллетеня: 10.07.2023 Бюл. № 7 Контактные реквизиты: 7 (812)328-3632, andrei.matveev@unipat.pu.ru	Автор(ы): Гришкин Валерий Михайлович (RU), Каримов Сардор Илхом угли (UZ) Правообладатель(и): федеральное государственное бюджетное образовательное учреждение высшего образования "Санкт-Петербургский государственный университет" (СПбГУ) (RU)
---	--

Название программы для ЭВМ:  
«Программа для распознавания и сегментации объектов на спутниковых снимках» (SatObj)

**Реферат:**

Программа «SatObj» является программой обработки изображений Земли, получаемых при спутниковом мониторинге определенных районов земной поверхности. Программа предназначена для автоматической сегментации спутниковых снимков на которых могут присутствовать следующие типы земной поверхности — сельскохозяйственные земли, пастбища, бесплодные земли, здания и сооружения, лесные массивы, водные массивы. Остальные типы, не входящие в этот перечень, отображаются как неизвестный тип. Программа выполняет следующие функции: создает глубокую нейронную сеть, с помощью которой происходит сегментация спутниковых изображений; реализует алгоритм обучения нейронной сети по имеющемуся набору размеченных данных спутниковых изображений; с помощью обученной нейронной сети определяет тип земной поверхности для каждого пикселя предъявляемого изображения и формирует карту распределения типов поверхности на спутниковом изображении.

Язык программирования: Python 3.7

Объем программы для ЭВМ: 17 МБ