

МИНИСТЕРСТВО ОБРАЗОВАНИЯ РЕСПУБЛИКИ БЕЛАРУСЬ
БЕЛОРУССКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ФАКУЛЬТЕТ ПРИКЛАДНОЙ МАТЕМАТИКИ И ИНФОРМАТИКИ
Кафедра компьютерных технологий и систем

КРЕЧ Анастасия Владимировна

**РЕКОНСТРУКЦИЯ СПЕКТРАЛЬНОГО ОБРАЗА ПО RGB
ИЗОБРАЖЕНИЯМ**

Дипломная работа

Научный руководитель:
Заведующий кафедрой
информационных систем управления,
доктор технических наук
А. М. Недзведь

Допущена к защите

« ___ » _____ 2025

Заведующий кафедрой компьютерных технологий и систем
доктор педагогических наук,
кандидат физико-математических наук,
профессор В.В. Казаченок

Минск, 2025

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	6
ГЛАВА 1 ОБЩИЕ СВЕДЕНИЯ	7
1.1 Роль цвета в феномике растений	7
1.2 Метамеры. Цвет. Спектр	8
1.3 Понятие гиперспектральных изображений	10
1.4 Особенности гиперспектральных изображений и их применение	11
1.5 Методы формирования гиперспектральных изображений.....	12
1.6 Ограничения и искажения реконструкции гиперспектральных данных	15
1.7 Теоретические основы реконструкции. Сверточные нейронные сети..	18
1.8 Выводы	21
ГЛАВА 2 ГИПЕРСПЕКТРАЛЬНОЕ ВОССТАНОВЛЕНИЕ.....	23
2.1 Деконволюция Руифрока-Джонстона	23
2.2 Архитектура HRNet и методы улучшения качества признаков	25
2.3 Функция потерь в HRNet.....	27
2.4 Нормализация данных и инициализация весов	28
2.5 Преобразование координат цвета в спектр	30
2.6 Коррекция спектра по базовым значения	34
2.7 Выводы	35
ГЛАВА 3 РЕАЛИЗАЦИЯ HRNet	37
3.1 Программные средства разработки	37
3.2 Набор данных	38
3.3 Процесс обучения модели	40
3.4 Стратегия объединения	42
3.5 Оценка качества восстановления с помощью HRNet.....	44
3.6 Извлечение значений интенсивности с помощью деконволюции.....	46
3.7 Программная реализация методов построения спектральных графиков	49
3.8 Выводы	53
ЗАКЛЮЧЕНИЕ	54
СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ	55

РЕФЕРАТ

Дипломная работа, 60 страница, 15 рисунков, 3 таблицы, 51 источников

Ключевые слова: МАШИННОЕ ОБУЧЕНИЕ, ГИПЕРСПЕКТРАЛЬНЫЕ ИЗОБРАЖЕНИЯ, СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ, СПЕКТР, ФЕНОМИКА, РЕКОНСТРУКЦИЯ, RGB.

Объект исследования: методы восстановления спектральной информации из изображений.

Предмет исследования: эффективность и особенности применения гиперспектрального восстановления и деконволюции для получения спектральных данных.

Цель исследования: определение наиболее эффективного метода генерации спектральных графиков на основе стандартных RGB-изображений путем сравнительного анализа подходов цветовой деконволюции и сверточных нейронных сетей.

Методы исследования: проведение сравнительного анализа двух различных подходов к восстановлению спектральной информации из RGB-изображений. Установка различия в точности и характеристиках получаемых спектральных графиков в зависимости от метода восстановления.

Полученные результаты их новизна: оценка восстановленных гиперспектральных изображений показала, что модель HRNet генерирует спектральную информацию с высокой точностью. Результаты реконструкции близки к реальным гиперспектральным изображениям, что подтверждает применимость нейронных сетей для задач мониторинга состояния растительности.

Достоверность материалов и результатов дипломной работы: использовались проверенные источники информации, включая научную литературу, рекомендованную научным руководителем, а также публикации победителей международных соревнований по компьютерному зрению. Результаты были проверены на практике с помощью популярных метрик качества и сравнительного анализа.

Область возможного практического применения: полученные результаты подтверждают достоверность предложенного подхода и позволяют рекомендовать его для использования в системах автоматизированного агромониторинга, направленных на раннюю диагностику заболеваний растений, оптимизацию применения удобрений и повышение экологической устойчивости сельского хозяйства.

РЭФЕРАТ

Дыпломная праца, 60 старонка, 15 малюнкаў, 3 табліцы, 51 крыніц.

Ключавыя словы: МАШЫННАЕ НАВУЧАННЕ, ГІПЕРСПЕКТРАЛЬНЫЯ ВЫЯВЫ, КАНВАЛЮЦЫЙНЫЯ НЕЙРОННЫЯ СЕТКІ, СПЕКТР, ФЕНОМІКА, РЭКАНСТРУКЦЫЯ, RGB.

Аб'ект даследавання: метады аднаўлення спектральнай інфармацыі з малюнкаў.

Прадмет даследавання: эфектыўнасць і асаблівасці прымянення гіперспектральнага аднаўлення і дэканвалюцыі для атрымання спектральных дадзеных.

Мэта даследавання: вызначэнне найбольш эфектыўнага метаду генерацыі спектральных графікаў на аснове стандартных RGB-выяў шляхам параўнальнага аналізу падыходаў каляровай дэканвалюцыі і свертчных нейронавых сетак.

Метады даследавання: правядзенне параўнальнага аналізу двух розных падыходаў да аднаўлення спектральнай інфармацыі з RGB-выяў. Вызначэнне адрозненняў у дакладнасці і характарыстыка атрыманых спектральных графікаў у залежнасці ад метаду аднаўлення.

Атрыманыя вынікі іх навізна: ацэнка адноўленых гіперспектральных выяў паказала, што мадэль HRNet генеруе спектральную інфармацыю з высокай дакладнасцю. Вынікі рэканструкцыі блізкія да рэальных гіперспектральных малюнках, што пацвярджае дастасавальнасць нейронавых сетак для задач маніторынгу стану расліннасці.

Дакладнасць матэрыялаў і вынікаў дыпломнай працы: выкарыстоўваліся правяраныя крыніцы інфармацыі, уключаючы навуковую літаратуру, рэкамендаваную навуковым кіраўніком, а таксама публікацыі пераможцаў міжнародных спаборніцтваў па кампутарным зроку. Вынікі былі правяраны на практыцы з дапамогай папулярных метрык якасці і параўнальнага аналізу.

Вобласць магчымага практычнага прымянення: атрыманыя вынікі пацвярджаюць дакладнасць прапанаванага падыходу і дазваляюць рэкамендаваць яго для выкарыстання ў сістэмах аўтаматызаванага агроманіторынга, накіраваных на раннюю дыягностыку захворванняў раслін, аптымізацыю прымянення угнаенняў і павышэнне экалагічнай устойлівасці сельскай гаспадаркі.

SUMMARY

Diploma work, 60 pages, 15 pictures, 3 tables, 51 sources.

Keywords: MACHINE LEARNING, HYPERSPECTRAL IMAGES, CONVOLUTIONAL NEURAL NETWORKS, SPECTRUM, PHENOMICS, RECONSTRUCTION, RGB.

The object of the research: methods of spectral information recovery from images.

The subject of the research: the effectiveness and features of using hyperspectral reconstruction and deconvolution to obtain spectral data.

The purpose of the study: to determine the most effective method for generating spectral graphs based on standard RGB images by comparative analysis of approaches to color deconvolution and convolutional neural networks.

Methods of research: conducting a comparative analysis of two different approaches to the restoration of spectral information from RGB images. Setting differences in the accuracy and characteristics of the obtained spectral graphs depending on the recovery method.

The results of the work and their novelty: Evaluation of the reconstructed hyperspectral images showed that the HRNet model generates spectral information with high accuracy. The reconstruction results are close to real hyperspectral images, which confirms the applicability of neural networks for vegetation monitoring tasks.

Authenticity of the materials and results of the diploma work: trusted sources of information were used, including scientific literature recommended by the supervisor, as well as publications by the winners of international computer vision competitions. The results were tested in practice using popular quality metrics and comparative analysis.

Recommendations on the usage: The results obtained confirm the validity of the proposed approach and allow us to recommend it for use in automated agricultural monitoring systems aimed at early diagnosis of plant diseases, optimizing the use of fertilizers and increasing the environmental sustainability of agriculture.

ВВЕДЕНИЕ

Изучение природных явлений в последние десятилетия все больше опирается на спектральный анализ. Особый интерес представляет анализ цвета и его спектральных характеристик на изображениях, так как они позволяют получать ценную информацию об исследуемых объектах.

Один из наглядных показателей состояния растений — их окраска. Изучение цветовых параметров растительности предоставляет ценную информацию, позволяющую не только идентифицировать и классифицировать растения, но также оценивать их состояние и выявлять потенциальные угрозы, такие как заболевания, воздействия вредителей и стрессовые условия [23]. Полученные данные могут стать основой для разработки более эффективных агротехнических стратегий — от полива и внесения удобрений до защиты растений от вредителей.

С использованием современных технологий анализ растений становится более точным, автоматизированным и эффективным. Все чаще применяются камеры в задачах мониторинга сельскохозяйственных культур. Однако не всегда удается получить достаточно информации из обычных фотографий, поскольку различные шумы и искажения могут сильно отразиться на результате анализа оценки состояния.

Целью данного исследования является извлечение спектральных характеристик из цветовых каналов, полученных с использованием современных технологий обработки изображений. Задача заключается в оценке эффективности различных методов и моделей, а также в выявлении наиболее точных и простых для интеграции подходов, способных восстанавливать значения интенсивности цвета из стандартных RGB-изображений для эффективного исследования объектов.

Результаты данной работы могут открыть новые перспективы для широкого применения гиперспектральной реконструкции в феномике растений. Синтезированные спектральные данные, полученные в результате восстановления, могут стать надежной основой для оценки стрессовых факторов, раннего выявления заболеваний и оптимизации агротехнических мероприятий.

ГЛАВА 1

ОБЩИЕ СВЕДЕНИЯ

1.1 Роль цвета в феномике растений

Феномика растений активно использует цветовую информацию в своих исследованиях, поскольку цвет является важным и ярким признаком фенотипа растений. Он обусловлен наличием различных пигментов и химических соединений, которые зависят от генетических особенностей растения и его взаимодействия с внешней средой [23, 44, с. 622].

Окраска листьев зависит прежде всего от их пигментного состава. Зеленый оттенок им придает хлорофилл, который участвует в процессе фотосинтеза. Каротиноиды, антоцианы и другие пигменты изменяют цвет листовой, защищая растения от солнечного излучения и привлекая опылителей. В течение вегетационного периода и смены сезонов соотношение пигментов и уровень хлорофилла изменяются, что приводит к изменению окраски листьев. На рисунке 1.1 показано, как цвет листовой отражает состояние растений. Данное свойство помогает им адаптироваться к изменениям фотопериода и температуры.



Рисунок 1.1 – Отражение состояния растения по цвету листьев

Цвет также служит сигналом для опылителей и распространителей плодов и семян [24]. Разнообразие окраски цветков привлекает насекомых-опылителей, а яркие оттенки плодов указывают на их зрелость, способствуя распространению семян животными. Наблюдая за изменениями цветовых характеристик растений, можно оценивать их состояние. Эти данные помогают не только предотвратить гибель растений, но и создать условия для повышения урожайности.

Изменения цвета можно фиксировать с помощью фотографий. В традиционных методах съемки и видеозаписи каждый пиксель получает свой цвет за счет сочетания интенсивностей трех базовых каналов: красного, зеленого и синего. Эти каналы отражают определенные участки видимого спектра, воспринимаемые человеческим глазом.

На самом деле спектральный состав света, отраженного или излученного объектом, значительно сложнее и охватывает весь видимый диапазон. Разложение света на спектральные компоненты позволяет не только определять цвет каждого пикселя, но и получать полный спектр, содержащий данные о молекулярном и химическом составе объекта. Например, на рисунке 1.2 авокадо выглядит свежим, без видимых вмятин или пятен на кожуре. Однако при съемке с использованием камеры, способной фиксировать дополнительные спектральные данные, внутренние дефекты становятся отчетливо заметными [35, с. 9].

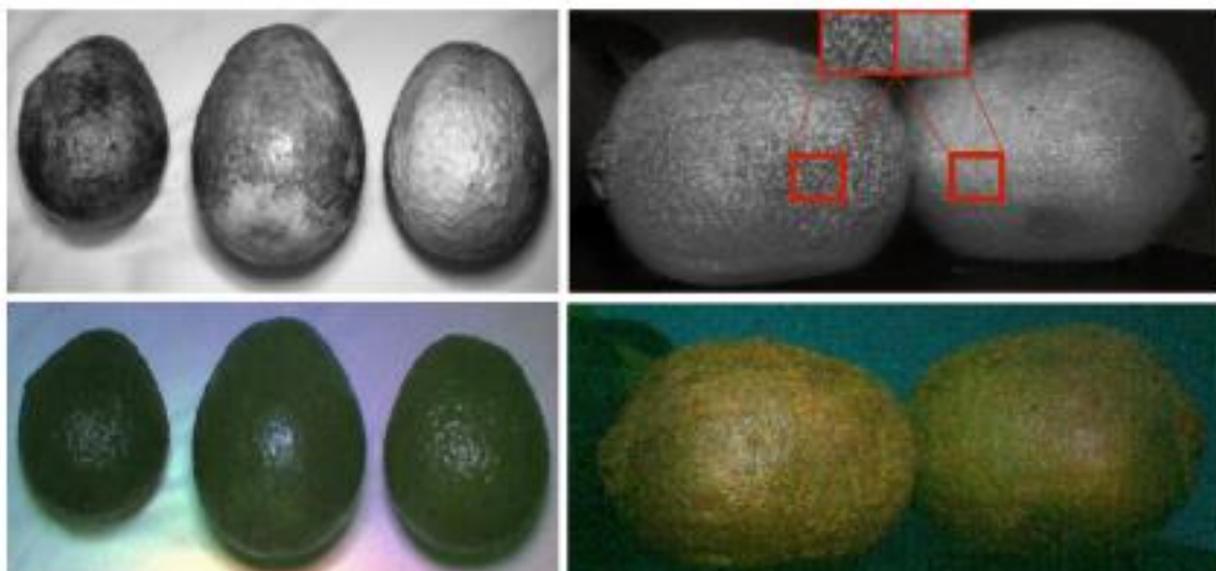


Рисунок 1.2 – Пример изображения с дополнительным информационным каналом

Информация, извлекаемая из таких изображений, дает возможность проводить точный спектральный анализ и идентификацию объектов. Данный процесс называется гиперспектральной съемкой и позволяет установить прямую связь между цветом пикселей и фактическим излученным спектром.

1.2 Метамеры. Цвет. Спектр

Окраска биологического объекта определяется двумя основными факторами. Один из них — структурная окраска, которая зависит от

особенностей поверхности, взаимодействующей со светом. Например, цветные полосы и пятна на лепестках некоторых растений, таких как ирисы и тюльпаны, возникают за счет микроструктуры клеток или тканей. Эти структуры отражают и преломляют свет, создавая насыщенные и яркие оттенки [42].

Однако ключевую роль в физиологии растений играет другой механизм окраски — химический, или биохимический. В его основе лежит способность молекул, известные в биологии как пигменты, поглощать и отражать свет в ультрафиолетовом и инфракрасном диапазонах. У растений они имеют прямое физиологическое значение. Например, зеленые хлорофиллы и оранжево-красные каротиноиды участвуют в фотохимических и метаболических процессах, а желтые, синие и фиолетовые флавоноиды помогают защитить растение от излучения и привлечь насекомых-опылителей [16].

Анализируя цвет растительного объекта, можно определить концентрацию входящих в него пигментов. Сведения о его структурном составе дают представление физиологического состояния. Однако человеческое зрение имеет ограничения: зрительная система воспринимает цвет через механизмы, которые не позволяют различать спектральные характеристики источников света. В результате два разных световых потока могут создавать одинаковое цветовое ощущение, даже если их спектры различны.

Явление метамерии можно наблюдать при изменении освещения. Как показано на рисунке 1.3, некоторые объекты при одном источнике света выглядят одинаковыми по цвету, но при другом освещении их оттенки заметно меняются.



Рисунок 1.3 – Проявление явления метамерии при изменении освещения

Понимание явления метамерии помогает учитывать влияние различных источников света на восприятие и корректную передачу цвета в разных условиях освещения.

1.3 Понятие гиперспектральных изображений

В отличие от традиционной цветной фотографии, гиперспектральные изображения предоставляют значительно больше спектральной информации. Вместо фиксированного цвета каждый пиксель содержит данные о полном спектре излучения или поглощения. Что позволяет точно соотнести оттенки на изображении с реальными характеристиками электромагнитного спектра объекта [5].

Трехмерная структура гиперспектральных изображений напоминает куб, в котором два измерения соответствуют пространственному разрешению, а третье — спектральному. Такая структура представлена на рисунке 1.4.

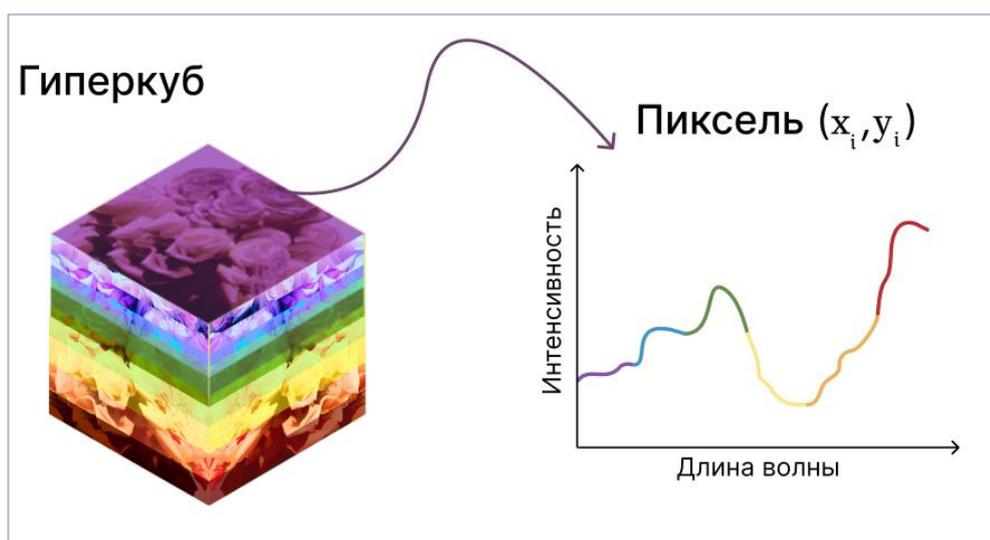


Рисунок 1.4 – Структура гиперспектрального изображения

В каждом пикселе изображения содержится полный спектральный состав, который включает сведения обо всех участках спектра, поглощенных или отраженных объектом [5].

Особенности гиперспектральных изображений:

Каждый узкий спектральный диапазон соответствует определенному участку спектра, будь то инфракрасная, видимая или ультрафиолетовая область.

Анализ спектра каждого пикселя позволяет изучить молекулярный и химический состав объекта.

Уникальный спектральный «отпечаток» объектов дает возможность их точной идентификации и классификации.

Алгоритмы и методы обработки гиперспектральных изображений были разработаны на основе исследований в области спектроскопии, а также обработки изображений и машинного обучения. Такое представление

информации применяется для задач, связанных с идентификацией целей и объектов, а также для анализа данных, полученных в условиях шума [22, 25, 31]. Исследования в области обработки данных и улучшения точности классификации также сыграли важную роль в создании эффективных алгоритмов, подходящих для работы с гиперспектральными изображениями.

1.4 Особенности гиперспектральных изображений и их применение

Зрительная система человека способна воспринимать электромагнитное излучение в ограниченном диапазоне волн, от 380 до 760 нм. Тем самым формируется область видимого спектра. При этом фоторецепторы глаз обладают чувствительностью к частично перекрывающимся зонам, которые соответствуют трем основным цветам: красному, зеленому и синему [1, с. 16]. Совокупность информации, полученной от этих трех диапазонов, позволяет мозгу человека интерпретировать различные цвета и оттенки. Видимый спектр представлен на рисунке 1.5.



Рисунок 1.5 – Световой спектр

Обычные камеры предназначены для получения изображений, которые человек способен воспринять. Однако ограниченный спектр поглощения, который охватывает только цветовую гамму, видимую глазу, и использование стандартных фильтров RGB приводят к потере множества деталей, скрытых в узких областях спектра. В то же время эти недостающие данные могут содержать значимую информацию. Даже небольшие различия в спектрах могут раскрывать ключевые особенности объектов. Подобные свойства применяются не только в природе, например, пчелы могут видеть в ультрафиолетовом свете, но и в научных исследованиях. Термин «гиперспектральная визуализация» используется для обозначения сенсорных систем, которые способны воспринимать более широкий спектр, выходящий за пределы стандартных RGB-диапазонов.

Спектральные свойства оказались полезными в различных областях, начиная от дистанционного зондирования [11], медицинской диагностикой [41] и заканчивая контролем качества фруктов и овощей [36, с. 17]. В последние годы гиперспектральные изображения находят применение в задачах компьютерного зрения, таких как сегментация, распознавание и отслеживание объектов. Данная тенденция свидетельствует о растущем использовании гиперспектральной визуализации в современных исследованиях. Однако стоит отметить, что большинство применений этой технологии ограничены лабораторными условиями. Специальное оборудование обычно громоздкое, дорогое и сложное в использовании, что сильно сужает область его применения. Основной задачей исследований в этой области является снижение стоимости технологии, улучшение удобства эксплуатации и уменьшение размеров оборудования.

1.5 Методы формирования гиперспектральных изображений

Методы создания гиперспектральных изображений можно условно разделить на две категории: прямые и обратные. Прямые методы, в свою очередь, предполагают использование специализированного оборудования. Часто используются камеры с повышенной чувствительностью, предназначенные для сбора данных, необходимых для формирования трехмерных кубов информации. Однако, как уже упоминалось, такие устройства требуют значительных финансовых затрат и ограничены в применении из-за своих габаритов.

Гиперспектральные камеры могут создавать изображения с помощью пяти основных способов [5]. Один из них — точечное сканирование. В этом подходе один детектор или датчик последовательно захватывает отдельные пиксели, строя изображение «точка за точкой». Во время сканирования датчик перемещается по объекту, либо объект перемещается под датчиком, и каждый пиксель получает полную спектральную информацию. Для формирования полного гиперспектрального изображения требуется несколько циклов сканирования. Точечное сканирование применяется, когда необходима высокая точность спектральных данных, например, в лабораторных исследованиях и медицинской визуализации, где важно обеспечить максимальную детализацию и точность информации для каждого пикселя.

Одним из альтернативных способов формирования трехмерного спектрального куба является линейное сканирование. В отличие от точечного

сканирования, в данном случае интенсивности цвета захватываются целыми строками пикселей. Датчик одновременно фиксирует информацию по всей линии, после чего перемещается, создавая гиперспектральное изображение «строка за строкой» [5]. Этот подход позволяет значительно быстрее собрать полное изображение по сравнению с точечным сканированием. Метод широко используется в дистанционном зондировании, например, спутниковая съемка и картографирование, и в промышленном контроле качества, где необходимо быстро обрабатывать большие поверхности, например, на конвейерных линиях.

Следующим подходом выделяют спектроскопию с преобразованием Фурье (Fourier-Transform Spectroscopy). Данный метод основан на использовании интерферометра, который разделяет световые волны разных длин и комбинирует их. В процессе изменения длины пути этих волн создаются интерференционные полосы, которые фиксируются детектором. Затем, с помощью преобразования Фурье, эти полосы преобразуются в спектр. Что позволяет получить спектр всей сцены сразу, без необходимости последовательного сканирования пикселей или линий.

$$I(p, \bar{\nu}) = I(\bar{\nu})(1 + \cos(2\pi\bar{\nu}p)). \quad (1.1)$$

При более детальном рассмотрении работы оптического Фурье-спектрографа видно, что в сигнале присутствует только одна частотная составляющая [20]. Таким образом, зависимость интенсивности света на детекторе от длины волны $\bar{\nu} = \frac{1}{\lambda}$ и разности хода в интерферометре p можно представить в виде формулы (1.1), где, в свою очередь, $I(\bar{\nu})$ — интенсивность излучения. В этом контексте разность хода является важным параметром, влияющим на точность определения спектра, поскольку она напрямую связана с интерференционными полосами, образующимися на детекторе. Эти полосы содержат информацию о спектральных характеристиках света, что позволяет проводить детальный спектральный анализ.

$$I(p) = \left(p, \int_0^{\infty} I(p, \bar{\nu}) d\bar{\nu} \right) = \left(p, \int_0^{\infty} I(\bar{\nu})(1 + \cos(2\pi\bar{\nu}p)) d\bar{\nu} \right). \quad (1.2)$$

При рассмотрении общей интенсивности света на детекторе, необходимо учесть все возможные значения разности хода p , что в свою очередь определяет полную картину спектра. Тогда общая интенсивность света на детекторе для всех p указана в (1.2).

Далее, применяя преобразования Фурье, спектр определяется по измерению $I(p)$. Для этого применяется интеграл Фурье, который позволяет извлечь спектральную информацию из зависимости интенсивности от разности хода p .

$$I(p) = 4 \int_0^{\infty} \left\{ I(p) - \frac{1}{2} I(0) \right\} \cos(2\pi \bar{\nu} p) d\bar{\nu}. \quad (1.3)$$

В формуле (1.3) $I(p)$ представляет собой интенсивность света в зависимости от разности хода, а $I(0)$ — это начальная интенсивность при $p = 0$. В этом случае, когда разность хода равна нулю, интерферометр не вносит фазовых изменений, и интенсивность измеряется без воздействия интерференции.

Применяется в лабораторных исследованиях, химическом анализе и медицинской визуализации. Также используется в исследованиях, где требуется высокая точность в анализе статических образцов.

Все ранее описанные методы требуют значительных вычислительных затрат и времени для получения итогового изображения. В связи с этим, рассматриваются более эффективные подходы, одним из которых является спектральное сканирование [5].

При использовании этого метода изображение фиксируется на одной длине волны за раз. Сначала собираются данные для определенной длины волны, затем длина волны изменяется, и процесс повторяется, пока не будет охвачена вся необходимая часть спектра. После завершения сканирования данные объединяются, формируя гиперспектральный куб, где каждый слой представляет изображение, полученное на одной из длин волн. Благодаря своей скорости и возможности получения данных по всем слоям куба, спектральное сканирование активно используется в медицине и биологии для съемки различных слоев тканей, а также в лабораторных исследованиях, где важно анализировать объект на различных длинах волн.

Наиболее быстрым методом получения изображений являются гиперспектральные камеры с высокой скоростью съемки. Эти камеры записывают гиперспектральное видео, захватывая несколько спектральных диапазонов одновременно, что позволяет анализировать изменяющиеся сцены в реальном времени. Обычно такие устройства жертвуют спектральным или пространственным разрешением ради скорости, но при этом сохраняют достаточную детализацию для решения большинства задач. Поэтому подходят для мониторинга производственных процессов, анализа динамических биологических процессов и для отслеживания быстропротекающих

химических реакций. Данные камеры используются в случаях, когда требуется оперативно реагировать на изменения в сцене.

Как видно из таблицы 1.1, на сегодняшний день уже существует множество устройств для получения гиперспектральных изображений, и каждый тип оборудования имеет свои сильные стороны и оптимально подходит для конкретных задач [5].

Таблица 1.1 — Сравнение типов формирования изображений

Метод	Преимущества	Ограничения
Точечное сканирование	Высокое спектральное разрешение, поскольку каждый пиксель содержит полную спектральную информацию.	Время сканирования может быть значительным из-за необходимости захватывать каждый пиксель отдельно.
Линейное сканирование	Высокая скорость сканирования при хорошем спектральном разрешении.	Требует, чтобы сцена или объект находились в постоянном движении относительно камеры.
Спектроскопия с преобразованием Фурье	Высокий световой поток позволяет собрать больше информации за одно измерение.	Малейшие вибрации могут нарушить интерференцию.
Спектральное сканирование	Быстрая съемка изображений для каждой длины волны.	Процесс формирования полного гиперспектрального куба занимает время.
Гиперспектральные быстрые камеры	Высокая скорость съемки.	Ограниченное спектральное или пространственное разрешение, что может повлиять на качество данных.

1.6 Ограничения и искажения реконструкции гиперспектральных данных

Столкнувшись с трудностями, которые приходится преодолевать при использовании прямых методов, ученые все чаще обращаются к обратным подходам для извлечения спектральной информации. Один из таких методов — восстановление гиперспектральных данных из стандартных изображений. Однако данный процесс сопровождается значительной потерей информации

на этапе спектральной интеграции, что делает задачу восстановления некорректной, а ее решение неоднозначным.

Операцию формирования изображения в визуализирующей системе можно представить в виде общей математической модели.

$$y = \mathcal{H}(x). \quad (1.4)$$

В уравнении (1.4) x обозначает истинное изображение, которое требуется восстановить, y — наблюдаемые данные, а оператор \mathcal{H} осуществляет проекцию из одного векторного пространства в другое [17, с. 14].

В данной работе рассматриваются задачи, где оператор \mathcal{H} является линейным преобразованием. Как правило, искомое изображение представляется в виде вектора $x \in R^N$. В зависимости от конкретной задачи, наблюдения могут иметь ту же размерность $y \in R^N$ или отличаться $y \in R^P$, где $N \neq P$. Первый случай характерен для микроскопии, тогда как второй часто встречается в однопиксельной визуализации. При этом оператор \mathcal{H} обычно представлен матрицей $H \in R^{P \times N}$, размер которой так же зависит от приложения.

Описанный процесс формирования изображения обычно называется прямым, в то время как алгоритм восстановления искомого изображения представляет собой обратную задачу. Решение обратной задачи часто сводится к оптимизации некоторого критерия, например, к поиску оценки \hat{x} , при которой $H\hat{x}$ наилучшим образом аппроксимирует y по методу наименьших квадратов [4, 2].

$$\hat{x} = \arg \min_x \|Hx - y\|_2^2. \quad (1.5)$$

Другими словами, решение должно минимизировать ошибку вида (1.5). Однако обратные задачи восстановления изображений, в том числе восстановление гиперспектральных данных, чаще всего являются некорректно поставленными, поскольку нарушают как минимум одно из трех условий корректности по Адамару [29]:

1. Существование решения;
2. Единственность решения;
3. Устойчивость решения — решение непрерывно зависит от входных данных, при незначительном изменении входных данных решение также меняется незначительно.

Таким образом, задача восстановления гиперспектральных изображений является плохо обусловленной. Это означает, что решение, найденное с

помощью уравнения (1.5), может либо не существовать, либо оказаться крайне нестабильным к малым изменениям измерений y .

В работе [18] предложен метод регуляризации, согласно которому решение находится путем минимизации следующего функционала.

$$\hat{x} = \arg \min_x \|Hx - y\|_2^2 + \gamma \Omega[x]. \quad (1.6)$$

В уравнении (1.6) $\gamma \Omega[x]$ играет роль регулирующего или стабилизирующего функционала, где γ — весовой коэффициент, регулирующий влияние регуляризации на процесс оптимизации, $\Omega[x]$ — функция, накладывающая дополнительные ограничения на решение.

$$\Omega[x] = \|x\|_2^2. \quad (1.7)$$

Уравнение (1.7) представляет собой квадратичную норму, которую часто используют в качестве второго члена уравнения (1.6). Методы регуляризации широко применяются в задачах восстановления изображений [50], позволяя смягчить проблему нестабильности решений.

Однако при восстановлении спектральных данных требуется отметить явление метамерии — ситуация, когда различные спектральные распределения могут восприниматься как один и тот же цвет. Это фундаментальное ограничение делает однозначное восстановление полного спектра невозможным для произвольных объектов.

Тем не менее, гиперспектральная реконструкция из RGB становится выполнимой для растительности благодаря предсказуемости ее спектральных характеристик. В отличие от синтетических материалов и большинства природных объектов, спектры отражения растений обусловлены биофизическими параметрами, такими как концентрация хлорофилла, каротиноидов и других пигментов, формирующих характерные спектральные особенности в диапазоне поглощения и отражения света.

Данные факторы определяют характерные зоны поглощения и отражения света [21], что позволяет достоверно реконструировать спектр, несмотря на проблему метамерии.

1.7 Теоретические основы реконструкции. Сверточные нейронные сети

Аппаратные системы, обеспечивающие прямой захват гиперспектральных изображений, отличаются высокой стоимостью производства и значительными габаритами, что делает их менее доступными для широкого спектра задач [41, 29]. Как правило, такие устройства находят применение в специализированных областях, — например, в сельском хозяйстве, экологии или медицине, — где их высокая цена и крупные размеры оправданы специфическими требованиями и задачами.

Несмотря на то, что гиперспектральный анализ сегодня применяется преимущественно в узкоспециализированных сферах, его потенциал значительно шире и способен найти применение в самых разных отраслях. Расширение области использования таких технологий требует разработки более компактных, доступных и энергоэффективных решений. Одним из перспективных направлений в этом контексте является реконструкция гиперспектральных данных на основе стандартных RGB-изображений. Такой подход позволяет получать спектральную информацию без использования дорогостоящих специализированных устройств, что существенно снижает порог вхождения в технологию.

Современные камеры, встроенные в смартфоны, обладают высокой разрешающей способностью, что делает их потенциальной платформой для интеграции методов спектрального анализа в повседневную практику. Тем самым открывает путь к созданию мобильных приложений для анализа, диагностики заболеваний растений, мониторинга окружающей среды и других задач, ранее недоступных без профессионального оборудования.

Как уже отмечалось в разделе 1.6, задача восстановления гиперспектральных данных из RGB-изображений по своей сути является некорректно поставленной. Это связано с тем, что при преобразовании гиперспектрального спектра в трехканальное RGB-представление происходит существенная потеря спектральной информации, что делает обратное преобразование крайне затруднительным. Кроме того, на RGB-изображения неизбежно влияет шум окружающей среды, артефакты оптики и сенсоров, что дополнительно снижает точность возможной реконструкции.

Тем не менее, несмотря на невозможность точного восстановления полного спектра, существует устойчивая взаимосвязь между RGB и гиперспектральными данными. Отмеченная корреляция может быть эффективно использована в рамках методов машинного обучения или нейросетевого моделирования. Обучая модели на большом количестве

соответствующих пар RGB и гиперспектральных изображений, можно добиться приемлемого уровня приближенной реконструкции спектральных характеристик. Такой подход позволяет частично компенсировать потерю информации и делает возможным применение спектрального анализа даже на базе обычных RGB-сенсоров [37].

RGB-изображения содержат значительно меньше спектральной информации по сравнению с гиперспектральными — одному RGB-изображению может соответствовать несколько гиперспектральных представлений. Поэтому для высококачественной реконструкции утраченных данных алгоритму необходимо определить оптимальную функцию отображения, обеспечивающую верное восстановление спектральной информации.

С развитием глубоких сверточных нейронных сетей (Convolutional Neural Networks, CNN) стало возможным построение моделей, способных восстанавливать спектр сигнала или изображения даже при отсутствии точных данных о процессе их формирования. Благодаря архитектуре, ориентированной на обработку пространственно-организованных данных, такие сети эффективно извлекают ключевые признаки — например, текстуры, границы и формы — с помощью операции свертки. Что позволяет моделям выявлять скрытые закономерности и выполнять задачи реконструкции с высокой степенью достоверности, даже в условиях ограниченной или искаженной информации.

Первые подходы к задаче реконструкции гиперспектральных данных опирались на методы разреженного кодирования, а позднее — на алгоритмы глубокого обучения. В 2008 году Пармар и его коллеги [40] представили метод расширенного разреженного кодирования, позволяющий восстанавливать пространственно-спектральные кубы, основываясь на ограниченном объеме входной информации.

Однако классические CNN сталкиваются с рядом ограничений: по мере увеличения глубины сети возникает проблема затухания или взрыва градиентов, что затрудняет обучение и снижает стабильность модели. Для преодоления этих трудностей в последующих исследованиях стали использовать ранее известные более устойчивые архитектуры, такие как автоматическое или разреженное кодирование [15, 19, 46], которые затем улучшались за счет применения остаточных блоков.

Ключевая особенность остаточных нейронных сетей (ResNet) заключается во внедрении так называемых shortcut-связей (или пропускных соединений), которые напрямую соединяют вход и выход каждого блока. Такой вид связей позволяет входному сигналу обходить один или несколько нелинейных слоев и передаваться дальше по сети без изменений. Результат

пропущенного входа затем суммируется с выходом основного пути, проходящего через сверточные и активационные операции [28].

$$H(x) = F(x) + x, \quad (1.8)$$

где $H(x)$ — итоговый выход блока,
 $F(x)$ — преобразованные данные (например, после сверточных слоев),
 x — входной сигнал.

Архитектура, представленная формулой (1.8), значительно упрощает обучение глубоких моделей, поскольку позволяет сохранять и передавать информацию через большое количество слоев без ее искажения.

Добавление shortcut-связей облегчает обучение, поскольку градиенты могут свободно проходить через прямую связь, что снижает вероятность их затухания. Также наличие этих связей позволяет добиться улучшения производительности за счет того, что модель может «пропускать» ненужные преобразования, если они не улучшают итоговый результат. Таким образом, ResNet позволяет строить глубокие архитектуры с меньшими потерями точности.

В последние годы для решения задач восстановления и генерации сложных данных были предложены усовершенствованные архитектуры нейронных сетей, развивающие идеи ResNet. Одной из наиболее значимых разработок в этом направлении является Dense Convolutional Network (DenseNet), которая представляет собой продолжение остаточных сетей, но с принципиально иной организацией соединений между слоями [32].

В отличие от ResNet, в которой некоторые связи пропускают один или несколько слоев, архитектура DenseNet основывается на понятии плотных соединений. В процессе работы модели каждый слой получает на вход, помимо результата работы предыдущего слоя, выходы всех более ранних слоев в пределах одного блока. Таким образом, каждый последующий слой имеет доступ ко всей совокупности ранее извлеченных признаков, что значительно увеличивает сохранение информации и способствует более эффективному обучению.

То есть, если слой l генерирует выход x_l , вход следующего слоя $l + 1$ включает все предыдущие выходы.

$$x_{l+1} = H([x_0, x_1, x_2, \dots, x_l]). \quad (1.9)$$

В математическом представлении (1.9) массив $[x_0, x_1, x_2, \dots, x_l]$ — объединение выходов всех предыдущих слоев, а H — функция, включающая операции свертки, нормализации и активации [32].

Сеть состоит из чередующихся плотных блоков и переходных слоев (Transition Layers). Плотные блоки содержат слои, которые соединяются друг с другом. Переходные слои уменьшают размерность данных, например, с помощью сверток размерностью 1×1 и пуллинга, чтобы предотвратить экспоненциальное увеличение размерностей. Графическая интерпретация структур ResNet и DenseNet представлена на рисунке 1.6.

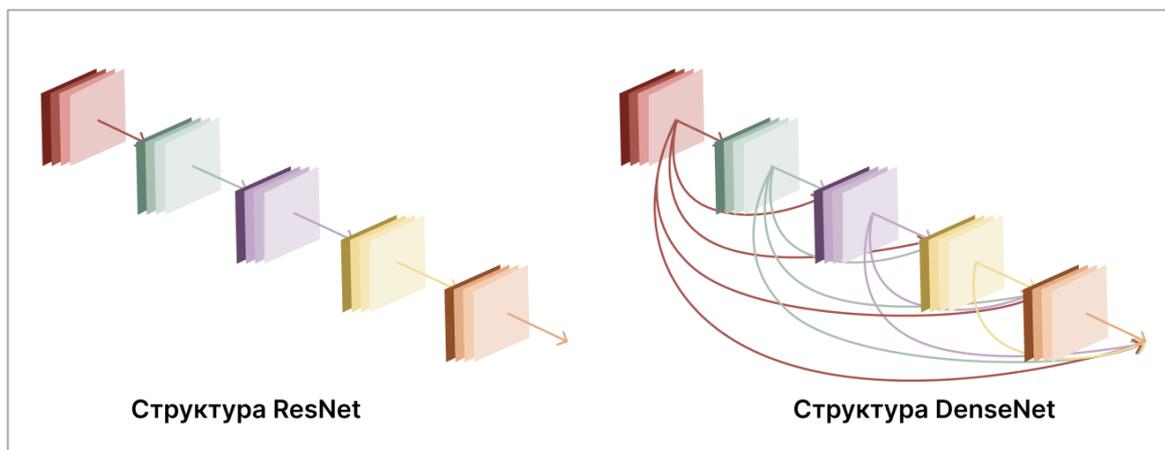


Рисунок 1.6 – Структура ResNet и DenseNet

DenseNet позволяет строить очень глубокие сети без риска затухания градиентов, как ResNet, но при этом требует меньше параметров благодаря плотным соединениям. Так, например, в [31] предложенная архитектура HSCNN-D улучшает результаты HSCNN, поскольку сокращает на 32% время реконструкции, а также уменьшает значение ошибки примерно на 7%.

Таким образом, рассмотренные архитектуры ResNet и DenseNet внедряют остаточные и плотные соединения, что позволило существенно повысить эффективность обучения глубоких моделей, улучшить сходимость и сохранить важные пространственные и спектральные зависимости. Использование данных подходов позволяет построить более точные и устойчивые системы восстановления гиперспектральной информации, открывая перспективы для их применения в условиях ограниченных вычислительных ресурсов и в реальном времени.

1.8 Выводы

Гиперспектральные изображения представляют собой мощный инструмент для детального анализа объектов и материалов. Они фиксируют спектральные характеристики на множестве узких длин волн, что позволяет различать объекты по уникальным спектральным подписям. Применение

пространственных данных открывает возможности для точной идентификации веществ, мониторинга состояния окружающей среды, диагностики заболеваний и решения других специализированных задач, которые ранее были недостижимы. В отличие от традиционных RGB-изображений, гиперспектральные снимки позволяют извлекать значительно больше информации о структуре и составе исследуемых объектов.

Однако, несмотря на перспективы применения технологии, широкое использование сдерживается высокой стоимостью и сложностью необходимого оборудования. Камеры, способные напрямую формировать гиперспектральные изображения, требуют больших затрат и обладают большими размерами, что ограничивает их доступность для многих сфер.

Тем не менее, существует множество подходов, которые позволяют значительно расширить применение гиперспектральных технологий, снижая зависимость от дорогостоящего и громоздкого оборудования. Например, метод реконструкции гиперспектральных характеристик из стандартных RGB-изображений представляет собой инновационное решение, которое позволяет получать спектральную информацию. С учетом повсеместного распространения смартфонов и других устройств с камерой, гиперспектральный анализ может стать более применимым в повседневных задачах и перейти в массовую технологию.

Практическая ценность данной работы состоит в том, что она рассматривает актуальные задачи восстановления изображений, которые применимы в различных областях науки.

ГЛАВА 2 ГИПЕРСПЕКТРАЛЬНОЕ ВОССТАНОВЛЕНИЕ

2.1 Деконволюция Руифрока-Джонстона

Для количественного анализа распределения интенсивностей по длинам волн необходимо выделить индивидуальный вклад каждого пикселя в общее изображение. Подобная задача известна в теории обработки сигналов и изображений как проблема обратной свертки, или деконволюции.

Из практических приложений данного подхода выделяется разделение цветовых компонентов на гистологических изображениях. В работе Руифрока и Джонстона была предложена методика деконволюции, позволяющая разложить итоговое цветовое значение пикселя на вклады отдельных красителей [49]. Поставленная задача особенно актуальна при окрашивании тканей несколькими контрастными веществами, где каждый краситель специфически маркирует определенные клеточные структуры. Поскольку камера фиксирует только итоговое RGB-изображение, в котором цвета различных красителей накладываются, необходимо применять методы, позволяющие восстановить индивидуальные сигналы — то есть определить вклад каждого красителя в формирование цвета пикселя.

$$\vec{i} \cdot \vec{p}^a \cdot \vec{q}^b \cdot \vec{r}^c \cdot \dots = \begin{bmatrix} i_1 \cdot p_1^a \cdot q_1^b \cdot r_1^c \cdot \dots \\ i_2 \cdot p_2^a \cdot q_2^b \cdot r_2^c \cdot \dots \\ i_3 \cdot p_3^a \cdot q_3^b \cdot r_3^c \cdot \dots \end{bmatrix}, \quad (2.1)$$

где \vec{i} представляет входной RGB-вектор света,
 $\vec{p}, \vec{q}, \vec{r}$ — векторы поглощения для разных веществ,
 a, b, c — толщина соответствующего вещества, через которое проходит свет,
 \vec{p}^a — поглощение света веществом p , возведенное в степень толщины a — по закону Бугера–Ламберта–Бера.

Основная идея предложенного подхода заключается в сохранении исходящего света при изменении порядка или разделении некоторых слоев. Данное предположение сформулировано формулой (2.1).

В работе описывается случай, когда свет \vec{i} проходит через три вещества. Также были известны векторы $\vec{v}, \vec{u}, \vec{w}$, описывающие скорости поглощения для всех веществ. Для каждого слоя вещества ширина, который может изменяться от точки к точке, была рассчитана с учетом освещенности на выходе. В работе

предполагалось, что камера регистрирует один вектор \vec{r} в некотором произвольном пикселе.

$$\vec{i} \cdot \vec{v}^a \cdot \vec{u}^b \cdot \vec{w}^c = \vec{r}, \quad (2.2)$$

Решение уравнения (2.2) для a, b и c дает значения ширины слоев в единицах длины. Далее вычисляется, какое количество света прошло через каждый слой отдельно. Первый шаг деконволюции представлен произведением $\vec{i} \cdot \vec{v}^a$, второй и третий — $\vec{i} \cdot \vec{u}^b$, $\vec{i} \cdot \vec{w}^c$. В некоторых случаях, например из-за шума в данных или других искажений, неотрицательных значений a, b, c , решающих уравнение (2.2), не существует.

$$\vec{r} \cdot \vec{v}^a \cdot \vec{u}^b \cdot \vec{w}^c, \quad (2.3)$$

Тогда восстановленное изображение будет отличаться от исходного. Полученное различие можно визуализировать по формуле (2.3).

$$\vec{i} \cdot \vec{v}^a = \vec{i} \cdot (\vec{v}^\lambda)^{\frac{a}{\lambda}}, \quad (2.4)$$

Отмечается, что изменение выбранной единичной толщины вещества в λ раз приводит к замене коэффициента a в каждом пикселе на $\frac{a}{\lambda}$. Однако при этом распределение плотности a , умноженное на ширину элемента, остается неизменным. Аналогично, выбор масштаба единичной толщины не влияет на интерпретируемый результат деконволюции. Математическое описание представлено формулой (2.4).

$$a \log v_k + b \log u_k + c \log w_k = \log \frac{r_k}{i_k}, \quad (2.5)$$

Уравнение (2.2) представляет собой систему из трех уравнений — по одному для каждой цветовой компоненты. Представление для k -й компоненты в логарифмической форме сформулировано формулой (2.5).

$$\begin{bmatrix} \log v_1 & \log u_1 & \log w_1 \\ \log v_2 & \log u_2 & \log w_2 \\ \log v_3 & \log u_3 & \log w_3 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \begin{bmatrix} \log \frac{r_1}{i_1} \\ \log \frac{r_2}{i_2} \\ \log \frac{r_3}{i_3} \end{bmatrix} \quad (2.6)$$

Переход от (2.5) к векторной записи представлен уравнением (2.6). Эта система имеет решение тогда и только тогда, когда матрицы логарифмов обратима, то есть заданные вещества линейно независимы, и входной свет i_k не равен нулю ни в одном канале [26]. С физической точки зрения первое условие означает, что ни одно вещество не может быть симитировано смесью двух других. Второе — изображение получено при наличии света во всех каналах.

Получив изображение, можно в каждом пикселях решить систему относительно a, b, c . Если какие-либо значения оказываются отрицательными, это означает, что цвет пикселя не может быть получен путем смешения только заданных веществ. В этом случае предполагается, что либо имело место загрязнение, шум, либо присутствует другое вещество, не входящее в модель, — такие отрицательные значения следует отбросить.

После обработки каждой точки рассмотренным способом получается восстановленное изображение, три отдельных изображения вещества и одно остаточное изображение, показывающее ошибку.

Предложенный в исследовании подход можно интерпретировать как частный случай задачи восстановления спектральной информации из RGB-изображения. По аналогии предлагается использовать априорные знания спектральных профилей, используемых объектом, что позволит использовать более простую и вычислительно эффективную линейную модель деконволюции.

2.2 Архитектура HRNet и методы улучшения качества признаков

Несмотря на долгую доминацию алгоритмов разреженного кодирования в задаче реконструкции гиперспектральных данных, дальнейшие улучшения результатов были достигнуты благодаря внедрению специализированных плотных блоков, которые позволили уточнить и доработать информацию [22, 25, 31]. Данный подход к реконструкции гиперспектральных изображений был рассмотрен в предыдущих исследованиях [15]. В общем виде его суть заключается в том, что сверточные нейронные сети обрабатывают данные с низким пространственным разрешением, что обеспечивает компактное представление элементов и более высокую вычислительную эффективность.

Однако с увеличением глубины сети возникают проблемы, связанные с потерей исходной информации о исходных пикселях. При применении сверточных операций к данным происходит уменьшение пространственного

разрешения изображения. Это связано с тем, что стандартные сверточные слои и слои с понижением размерности, например, слои «пуллинга» или свертки с шагом больше единицы, «сворачивают» информацию в меньшие по размеру представления. Такой процесс часто называется понижающей выборкой, он приводит к потере части пиксельной информации, поскольку исходное изображение становится менее детализированным. Для преодоления представленного недостатка предлагается использовать PixelShuffle [45, 43]. Основная идея рассматриваемого оператора заключается в том, чтобы преобразовывать представление изображения с низким разрешением в представление с высоким разрешением, используя более эффективный способ перестановки (шлифовки) пикселей.

Кроме того, для повышения качества создаваемых изображений стоит использовать иерархическую архитектуру, позволяющую извлекать объекты разных масштабов. На каждом уровне данные проходят обработку через PixelUnShuffle. Данный оператор предназначен для уменьшения разрешения изображения. При его использовании пиксельные данные преобразуются в каналы. Таким образом, PixelShuffle расширяет изображение, раскладывая каналы по пространственным координатам, а PixelUnShuffle работает в обратном направлении: он уменьшает пространственное разрешение, «сворачивая» пиксели в дополнительные каналы. Что предотвращает потерю информации [34].

В рассматриваемой архитектуре также интегрированы остаточные плотные и глобальные блоки, что делает ее схожей с HRNet (High-Resolution Network). Ключевая особенность данной модели сети заключается в способности поддерживать высокое разрешение на протяжении всей глубины сети, что позволяет эффективно извлекать более точные и детализированные пространственные признаки. Остаточные плотные блоки помогают снизить уровень шумов, в то время как остаточные глобальные блоки способствуют улучшению моделирования удаленных корреляций между пикселями, что, в свою очередь, повышает общую точность восстановления данных [30].

Для нижнего уровня, где признаки представляют собой сжатые или обобщенные данные с уменьшенным пространственным разрешением, в архитектуру сети вводится сверточный слой размером 1×1 . Этот слой выполняет функцию усиления тонального отображения (Tone Mapping), достигаемую за счет взвешивания информации во всех каналах, что способствует улучшению представления данных и восстановлению деталей. На среднем уровне обработки признаки подвергаются обработке для различных масштабов, что позволяет эффективно захватывать информацию, соответствующую разным аспектам данных. Верхний уровень сети, в свою очередь, использует наибольшее количество блоков для интеграции

признаков, обеспечивая их эффективное слияние и минимизируя искажения. Данный подход позволяет добиться высокого качества восстановления, сохраняя важные детали и снижая потери информации при обработке [30]. Структура HRNet представлен на рисунке 2.1.

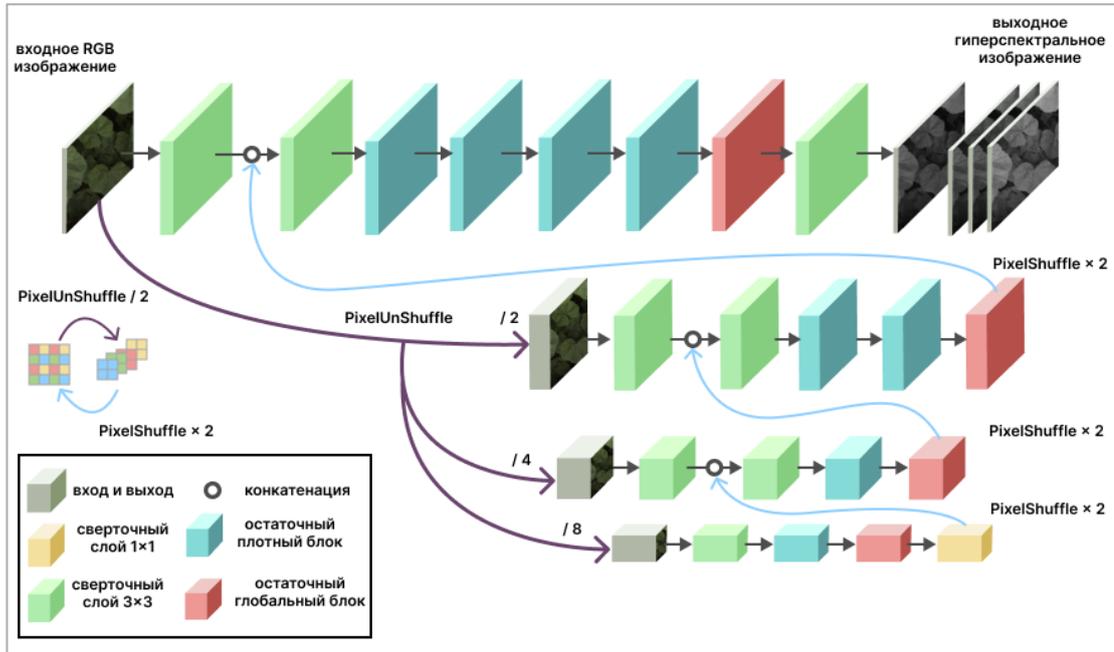


Рисунок 2.1 – Иллюстрация архитектуры HRNet

2.3 Функция потерь в HRNet

В процессе обучения предлагается использовать функцию потерь L_1 , ориентированную на повышение пикового отношения сигнала к шуму.

$$L_1 = E(\|G(x) - y\|_1), \quad (2.7)$$

где x и y — входные и выходные данные соответственно, $G(\cdot)$ — предлагаемая сеть HRNet.

Математическое представление функции L_1 задается формулой (2.7). Для повышения эффективности обучения также используется подход, основанный на локальных фрагментах, при котором как входное RGB-изображение, так и соответствующие выходные спектральные изображения обрезаются в одной и той же области с одинаковым пространственным разрешением. Данный метод позволяет моделям сосредоточиться на обработке информации в ограниченных областях, что способствует улучшению точности извлечения признаков.

Совмещение пространственного разрешения входных и выходных данных помогает избежать потери спектральной информации и улучшает синхронизацию между различными слоями сети. В результате, такая стратегия способствует более эффективному обучению модели, позволяя ей лучше учитывать пространственно-связанную информацию.

$$f(x) = \begin{cases} x, & \text{если } x > 0, \\ 0, & \text{если } x \leq 0. \end{cases} \quad (2.8)$$

В архитектуре сети все слои, за исключением выходного слоя, активируются с помощью LeakyReLU [47]. Функция Leaky Rectified Linear Unit — это модификация популярной функции активации ReLU, описанная формулой (2.8), которая решает проблему затухания градиента для отрицательных входов. Это означает, что все отрицательные значения заменяются на ноль, что может привести к «деактивации» некоторых нейронов и их отсутствию в процессе обучения.

$$f(x) = \begin{cases} x, & \text{если } x > 0, \\ \alpha x, & \text{если } x \leq 0, \end{cases} \quad (2.9)$$

где α — небольшая положительная константа.

В отличие от базовой функции в LeakyReLU вводится небольшое наклонное значение для отрицательных входов. И ее представление можно записать формулой (2.9).

Таким образом, решается одно из самых неприятных ограничений — затухание градиента, замедляющее и ухудшающее обучение. Поскольку отрицательные значения масштабируются, а не обнуляются, предлагаемый подход позволяет передавать информацию через сохраненные нейроны и обновлять их веса во время обучения, что значительно повышает эффективность сети.

2.4 Нормализация данных и инициализация весов

В нейронных сетях нормализация данных обычно применяется для стабилизации и ускорения процесса обучения, приводя входные данные к единому масштабу и устраняя проблемы, связанные с изменением их распределения. Однако нормализация может изменять статистические свойства данных, что в некоторых случаях может негативно сказаться на точности предсказаний. В контексте архитектуры HRNet, которая

ориентирована на сохранение детализированных признаков на каждом этапе обработки, отказ от нормализации помогает избежать потери информации и способствует более точному извлечению признаков.

Для минимизации граничных эффектов, возникающих при применении сверточных операций, в HRNet используется метод отражающего дополнения (reflect padding) [30]. Этот подход заключается в добавлении значений за пределами изображения, используя зеркальное отражение исходных данных. Такой метод помогает предотвратить искажения на границах изображения, что позволяет сохранить целостность признаков на всех уровнях сети.

Хотя HRNet не относится к генеративным моделям, в ней используются отдельные принципы, характерные для таких сетей, как VCGAN, применяемых при генерации изображений или восстановлении их контекста. Один из таких принципов — подход к эффективной интеграции информации на различных уровнях сети, что способствует улучшению качества извлекаемых признаков.

Кроме того, для инициализации весов в HRNet используется алгоритм Xavier [51], который обеспечивает оптимальный баланс между распределением входных и выходных данных для каждого нейрона, поскольку основан на принципе сохранения дисперсий активаций и градиентов обратного распространения.

$$W \sim U \left\{ -\sqrt{\frac{6}{n_{in} + n_{out}}}, \sqrt{\frac{6}{n_{in} + n_{out}}} \right\}. \quad (2.10)$$

Данный метод инициализации назван нормализованной инициализацией, позволяющий избежать проблем с затуханием или взрывом градиентов, обеспечивая стабильность обучения и ускоряя сходимость модели. Формирование веса W представлено формулой (2.10).

$$W \sim N \left(0, \frac{2}{n_{in} + n_{out}} \right). \quad (2.11)$$

Нормированное распределение веса W можно получить из формулы (2.11), где n_{in} — количество входящих соединений или нейронов предыдущего слоя, n_{out} — количество выходящих соединений, то есть нейронов текущего слоя.

Алгоритм Xavier предотвращает чрезмерное затухание или резких взрывов градиентов при обратном распространении ошибки, что позволяет сети быстрее сходиться и избегать плохих локальных минимумов [51].

2.5 Преобразование координат цвета в спектр

Альтернативный подход к восстановлению гиперспектральной информации основан на использовании интегральных уравнений, описывающих преобразование спектрального распределения данных в цветовое пространство RGB. Такой метод позволяет формализовать связь между гиперспектральными данными и привычной цветовой репрезентацией, широко применяемой в компьютерной графике, визуализации и цифровой обработке изображений.

$$x = \int_{380}^{780} \bar{x}_\lambda \varphi(\lambda) d\lambda. \quad (2.12)$$

Ключевая идея метода заключается в вычислении координат цвета в пространстве CIE XYZ с последующим преобразованием их в RGB [12]. Координаты x определяются интегральными уравнениями (2.12).

$$y = \int_{380}^{780} \bar{y}_\lambda \varphi(\lambda) d\lambda. \quad (2.13)$$

Интеграл (2.13) описывает вычисление координаты y в цветовом пространстве XYZ на основе спектрального распределения.

$$z = \int_{380}^{780} \bar{z}_\lambda \varphi(\lambda) d\lambda. \quad (2.14)$$

Интеграл (2.14) задает координату z , отвечающую за восприятие синего компонента цвета.

$$rgb = M \cdot xyz. \quad (2.15)$$

Итоговое RGB-изображение формируется в результате преобразования, представленного уравнением (2.15), где M — матрица преобразования координат цвета из XYZ в RGB пространство.

В уравнениях (2.12), (2.13), (2.14) переменные \bar{x}_λ , \bar{y}_λ , \bar{z}_λ — функции чувствительности XYZ, $\varphi(\lambda)$ — функция плотности распределения яркости (интенсивности) или другой световой величины.

Поскольку преобразование из цветового пространства RGB в XYZ является однозначным, то есть каждому цвету в RGB соответствует строго определенная точка в пространстве XYZ, это означает, что существует решение системы уравнений, связывающей координаты цвета x , y , z с его спектральным составом [6]. При этом вместо непрерывных интегралов, описывающих преобразование между спектром излучения и цветовыми координатами, можно использовать дискретную аппроксимацию — то есть заменить интегралы суммами по длинам волн с фиксированным шагом. Такой подход позволяет получить систему линейных уравнений.

$$\begin{cases} x = \Delta\lambda \sum_{i=1}^N \bar{x}_{\lambda_i} \varphi(\lambda_i), \\ y = \Delta\lambda \sum_{i=1}^N \bar{y}_{\lambda_i} \varphi(\lambda_i), \\ z = \Delta\lambda \sum_{i=1}^N \bar{z}_{\lambda_i} \varphi(\lambda_i). \end{cases} \quad (2.16)$$

При $N > 3$ система (2.16) имеет множество решений, которые могут быть выражены в виде линейной комбинации отдельных решений. Для нахождения разрешения системы используется следующий алгоритм.

В цикле для каждой длины волны в спектральном интервале выбираются три новые длины волн $(\lambda_i, \lambda_j, \lambda_k)$.

Для выбранных волн находится отдельное решение l -ой компоненты уравнения.

$$\begin{cases} x = \Delta\lambda \sum_{i=1}^N \left(\bar{x}_{\lambda_i} \varphi_l(\lambda_i) + \bar{x}_{\lambda_j} \varphi_l(\lambda_j) + \bar{x}_{\lambda_k} \varphi_l(\lambda_k) \right), \\ y = \Delta\lambda \sum_{i=1}^N \left(\bar{y}_{\lambda_i} \varphi_l(\lambda_i) + \bar{y}_{\lambda_j} \varphi_l(\lambda_j) + \bar{y}_{\lambda_k} \varphi_l(\lambda_k) \right), \\ z = \Delta\lambda \sum_{i=1}^N \left(\bar{z}_{\lambda_i} \varphi_l(\lambda_i) + \bar{z}_{\lambda_j} \varphi_l(\lambda_j) + \bar{z}_{\lambda_k} \varphi_l(\lambda_k) \right). \end{cases} \quad (2.17)$$

Если система линейных уравнений (2.17) имеет решение в виде $(\varphi_l(\lambda_i), \varphi_l(\lambda_j), \varphi_l(\lambda_k))$, причем все значения спектральной плотности $\varphi_l(\lambda)$ являются неотрицательными, то к исходному решению может быть добавлена следующая компонента [6].

$$\begin{cases} \varphi(\lambda_i) = \varphi(\lambda_i) + \varphi_l(\lambda_i), \\ \varphi(\lambda_j) = \varphi(\lambda_j) + \varphi_l(\lambda_j), \\ \varphi(\lambda_k) = \varphi(\lambda_k) + \varphi_l(\lambda_k). \end{cases} \quad (2.18)$$

Поскольку выражение (2.18) также удовлетворяет исходной системе уравнений, оно может быть интерпретировано как часть общего решения, соответствующего физически допустимому (неотрицательному) спектру.

По завершению вычислительного цикла получается ненормированная спектрограмма $\varphi(\lambda_i)$, представляющая собой сумму всех допустимых частных решений. Очевидно, что для данной суммы нормирующим множителем выступает общее число найденных допустимых решений L .

Для приведения спектральной плотности к форме, удовлетворяющей исходной системе линейных уравнений (2.16), необходимо выполнить нормировку, которая выражается следующими формулами.

$$\begin{cases} x = \Delta\lambda \sum_{i=1}^N \bar{x}_{\lambda_i} \frac{1}{L} \sum_{l=1}^{L_i} \varphi_{i_l}(\lambda_i), \\ y = \Delta\lambda \sum_{i=1}^N \bar{y}_{\lambda_i} \frac{1}{L} \sum_{l=1}^{L_i} \varphi_{i_l}(\lambda_i), \\ z = \Delta\lambda \sum_{i=1}^N \bar{z}_{\lambda_i} \frac{1}{L} \sum_{l=1}^{L_i} \varphi_{i_l}(\lambda_i). \end{cases} \quad (2.19)$$

В системе уравнений (2.19) переменная L_i — общее количество найденных допустимых решений для длины волны λ_i , $\varphi_i(\lambda_i)$ — найденное частное решение l -ой функции спектральной плотности для длины волны λ_i .

Следует отметить, что спектрограмма, полученная в результате работы алгоритма, обладает хорошей представительной способностью, поскольку она учитывает все допустимые решения в пределах всего диапазона видимого спектра. Что обеспечивает наиболее полное описание возможных спектральных реализаций заданного RGB-цвета [6].

Однако при переходе к задаче вычисления спектральных коэффициентов отражения поверхности прямое применение выражений (2.12) – (2.19) оказывается невозможным. Это связано с тем, что поверхность не обладает собственным цветом — ее цветовое восприятие формируется за счет отраженного, преломленного или рассеянного света, поступающего от

внешнего источника освещения. В колориметрии таким источником, как правило, выступает стандартный белый свет, например, освещение типа D₆₅.

Соответственно, для корректного вычисления спектральных характеристик отражения необходимо учитывать взаимодействие падающего спектра источника с отражательной способностью поверхности, а не рассматривать спектрограмму как самостоятельный источник излучения.

$$\begin{pmatrix} x_{D_{65}} = \int_{380}^{780} \bar{x}_{\lambda} D_{65}(\lambda) d\lambda \\ y_{D_{65}} = \int_{380}^{780} \bar{y}_{\lambda} D_{65}(\lambda) d\lambda \\ z_{D_{65}} = \int_{380}^{780} \bar{z}_{\lambda} D_{65}(\lambda) d\lambda \end{pmatrix} = \begin{pmatrix} x_{\rho} = \int_{380}^{780} \bar{x}_{\lambda} \rho(\lambda) D_{65}(\lambda) d\lambda \\ y_{\rho} = \int_{380}^{780} \bar{y}_{\lambda} \rho(\lambda) D_{65}(\lambda) d\lambda \\ z_{\rho} = \int_{380}^{780} \bar{z}_{\lambda} \rho(\lambda) D_{65}(\lambda) d\lambda \end{pmatrix}. \quad (2.20)$$

Аналогом выражений (2.12) – (2.14), применяемых для описания излучающих источников света, в случае отражающих или пропускающих поверхностей является выражение (2.20).

$$rgb_{\rho} = M \cdot xyz_{\rho}. \quad (2.21)$$

Уравнение (2.21) описывает RGB-компоненты света с характеристиками $\rho(\lambda)$, где $\rho(\lambda)$ — спектральные свойства отражения (пропускания) поверхности.

$$rgb_{D_{65}} = M \cdot xyz_{D_{65}}. \quad (2.22)$$

Уравнение (2.22) описывает RGB-компоненты самого источника D₆₅, по аналогии с выражением (2.15).

$$r = \frac{r_{\rho}}{r_{D_{65}}}; \quad g = \frac{g_{\rho}}{g_{D_{65}}}; \quad b = \frac{b_{\rho}}{b_{D_{65}}}. \quad (2.23)$$

Отношение (2.23) нормирует цвет поверхности относительно белого источника, моделируя воспринимаемый цвет при отражении от нейтрально-белой поверхности. Рассматриваемый подход соответствует классической модели освещения в колориметрии, где цвет поверхности определяется не

самим спектром, а спектром света, прошедшим через ее фильтрующие (отражающие) свойства.

Поскольку спектральный состав освещения D_{65} задан, можно использовать ранее описанный алгоритм (2.17) – (2.19), адаптировав его под задачу восстановления спектра отражения $\rho(\lambda)$. В этом случае вместо спектральной плотности $\varphi_{i_l}(\lambda_i)$ вычисляются значения $\rho_{i_l}(\lambda_i)$, описывающие отражательные свойства.

При этом накладывається физически обоснованное ограничение на значение спектра поверхности — отражение не может превышать полного, поэтому вводится следующее условие.

$$\frac{1}{L} \sum_{l=1}^{L_i} \rho_{i_l}(\lambda_i) \leq 1. \quad (2.24)$$

Ограничение (2.24) гарантирует, что усредненный спектральный коэффициент отражения на каждой длине волны не превышает 1, то есть не выходит за пределы физических возможностей отражающей поверхности.

2.6 Коррекция спектра по базовым значениям

Коррекция базовой линии представляет собой один из важнейших этапов предварительной обработки спектроскопических данных, направленный на отделение реальных аналитических сигналов от различных нежелательных эффектов — таких как фоновые помехи, интерференционные артефакты, следы загрязнений или остаточные отклики соединений. Коррекция позволяет устранить смещения, обусловленные неконтролируемыми внешними или внутренними факторами, и тем самым обеспечить достоверную интерпретацию результатов [33].

В зависимости от конкретных характеристик спектра и типа искажений, коррекция базовой линии может требовать применения различных подходов. В некоторых случаях для определенных частей спектра используется жесткая базовая линия, которая ограничена малой кривизной, что позволяет корректировать фоновый сигнал с минимальными изменениями формы. В других случаях, когда фон меняется более динамично, требуется гибкая базовая линия с большой кривизной, способная точно отслеживать изменения фона. Поэтому процесс коррекции часто предполагает необходимость

балансировать между различными методами для достижения оптимального результата.

Хотя для большинства задач можно использовать стандартные алгоритмы коррекции базовой линии, такие как полиномиальные аппроксимации или методы, основанные на минимальных точках и скользящих окнах, иногда такие алгоритмы оказываются неэффективными в определенных областях спектра. В таких случаях важно найти компромисс между различными подходами или же использовать отдельные корректировки для разных участков спектра. Данный подход может включать в себя локальную настройку параметров кривизны базовой линии, чтобы обеспечить наиболее точное и сбалансированное исправление и избежать как переобработки, так и недообработки данных [14].

Коррекция базовой линии используется для множества целей, таких как подавление или усиление определенных частот, удаление постоянной составляющей в сигнале или изменение частотного баланса. Этот процесс критически важен как перед спектроскопической интерпретацией данных, так и перед количественным анализом. Устранение фоновых эффектов помогает подготовить спектры для дальнейших этапов анализа, таких как идентификация веществ или построение аналитических моделей.

2.7 Выводы

В данной главе был рассмотрен альтернативный метод получения спектра через деконволюцию изображения, предоставляющий возможность реконструкции утерянных данных из изображений на основе обратной свертке сигналов.

Применение деконволюции Руифрока–Джостана расширяет возможности анализа материалов и объектов по изображениям, полученным с использованием недорогих или ограниченных по техническим характеристикам сенсоров. Таким образом, метод представляет собой перспективный инструмент для гиперспектрального анализа в условиях, когда прямое спектральное измерение затруднено или невозможно.

Кроме того, с целью расширения возможностей применения гиперспектральных изображений в различных научных и технических областях в рамках данного исследования была рассмотрена архитектура HRNet. Представленная модель выделяется своей способностью сохранять высокое разрешение на всех уровнях сети. Высокая детализация достигается благодаря многомасштабному подходу к обработке изображений, при котором

несколько потоков с различными разрешениями обрабатываются параллельно. Результаты каждого слоя интегрируются с помощью плотных блоков, что позволяет получить более точный и комплексный результат. Такой подход улучшает извлечение как мелких, так и крупных деталей изображения, что повышает общую эффективность модели при решении задач реконструкции гиперспектральных изображений.

Особенность архитектуры HRNet заключается в ее способности работать с данными на разных уровнях абстракции и разрешения, что позволяет сохранить как пространственные, так и спектральные характеристики изображений.

Таким образом, в данной главе описаны различные методы обработки и реконструкции гиперспектральных изображений. Представленные технологии способствуют расширению сфер применения спектральных данных, обеспечивая высокую точность и детализированное представление информации об исследуемых объектах.

ГЛАВА 3

РЕАЛИЗАЦИЯ HRNet

3.1 Программные средства разработки

Для реализации нейронной сети и алгоритма реконструкции гиперспектральных изображений был выбран язык программирования Python, благодаря его широкому набору специализированных библиотек, предназначенных для научных и инженерных вычислений. В качестве основного инструмента для выполнения математических операций и обработки массивов данных использовалась библиотека NumPy [7]. Она позволяет оперировать с многомерными массивами и матрицами, что необходимо при работе с гиперспектральными изображениями, представляющими собой многоканальные кубы спектральных данных. Методы NumPy позволили эффективно производить предварительную обработку, трансформацию и анализ спектральных данных.

Для более сложных вычислительных операций, требующих высокой точности и производительности, была задействована библиотека SciPy [9], расширяющая функциональность NumPy и предоставляющая спектр инструментов для решения задач численной оптимизации, линейной алгебры, интерполяции и статистического анализа. Использование SciPy значительно ускорило процесс разработки и обучения моделей, а также повысило точность и устойчивость алгоритмов реконструкции.

Основная часть работы с нейронной сетью была реализована с помощью TensorFlow — открытой библиотеки, разработанной компанией Google, которая предоставляет все необходимые инструменты для создания, обучения и тестирования моделей глубокого обучения [10]. TensorFlow отличается высокой гибкостью, масштабируемостью и поддержкой вычислений на графических процессорах, что делает его удобным решением для реализации ресурсоемких алгоритмов, таких как реконструкция гиперспектральных изображений. Для упрощения процесса проектирования архитектур нейронных сетей, а также для ускорения прототипирования и обучения моделей, применялась высокоуровневая обертка над TensorFlow — Keras. Этот инструмент обеспечивает интуитивно понятный интерфейс и позволяет легко настраивать, обучать и оценивать сложные модели без необходимости углубляться в низкоуровневую реализацию.

Поскольку обработка многополосных данных требует значительных вычислительных ресурсов из-за их высокой размерности и объема, ключевую

роль сыграло использование графических процессоров (GPU) для параллельных вычислений. По этой причине в рамках работы также была задействована библиотека PyTorch [8], которая обеспечивает высокую производительность при работе с большими массивами данных и предлагает удобные механизмы для обучения нейросетей на GPU. Благодаря своей динамической вычислительной графике и простой интеграции с CUDA, PyTorch стал результативным инструментом для ускоренной обработки спектральной информации и реализации современных архитектур глубокого обучения.

В процессе разработки было отмечено, что одним из ключевых аспектов исследования, наряду с обработкой многоканальных данных, является их эффективное хранение и организация доступа. Из-за высокой размерности и объема гиперспектральных изображений, выбор формата хранения данных играет важную роль в обеспечении производительности и масштабируемости системы. Для решения этой задачи был выбран формат HDF5 (Hierarchical Data Format version 5) — мощный и гибкий стандарт хранения данных, специально разработанный для работы с большими многомерными массивами. HDF5 обеспечивает высокую скорость чтения и записи, поддержку структурированных данных и возможность организации их в виде иерархических групп, что делает его идеальным решением для поставленной задачи.

В Python для взаимодействия с файлами формата HDF5 использовались библиотеки `hdf5storage` и `h5py`. Данные инструменты предоставляют удобные интерфейсы для интеграции HDF5 с массивами NumPy, а также позволяют осуществлять экспорт и импорт данных в форматы, используемые в MATLAB, что обеспечивает межплатформенную совместимость и гибкость при работе с различными программными средами. Кроме того, они позволяют легко выполнять операции сохранения, извлечения и манипулирования данными, что существенно ускорило процесс подготовки данных и интеграции их в рабочий процесс обучения нейронной сети.

3.2 Набор данных

В качестве обучающего набора данных для разработки и тестирования рассматриваемой модели были использованы материалы, предоставленные в рамках соревнований по обработке и улучшению изображений, проводимых на одной из ведущих международных конференций в области компьютерного зрения — CVPR (Conference on Computer Vision and Pattern Recognition).

Использованный набор данных включает в себя три ключевых компонента: спектральные изображения, набор «чистых» RGB-изображений (Clean RGB images) и набор RGB-изображений, полученных в реальных условиях (Real-world RGB images).

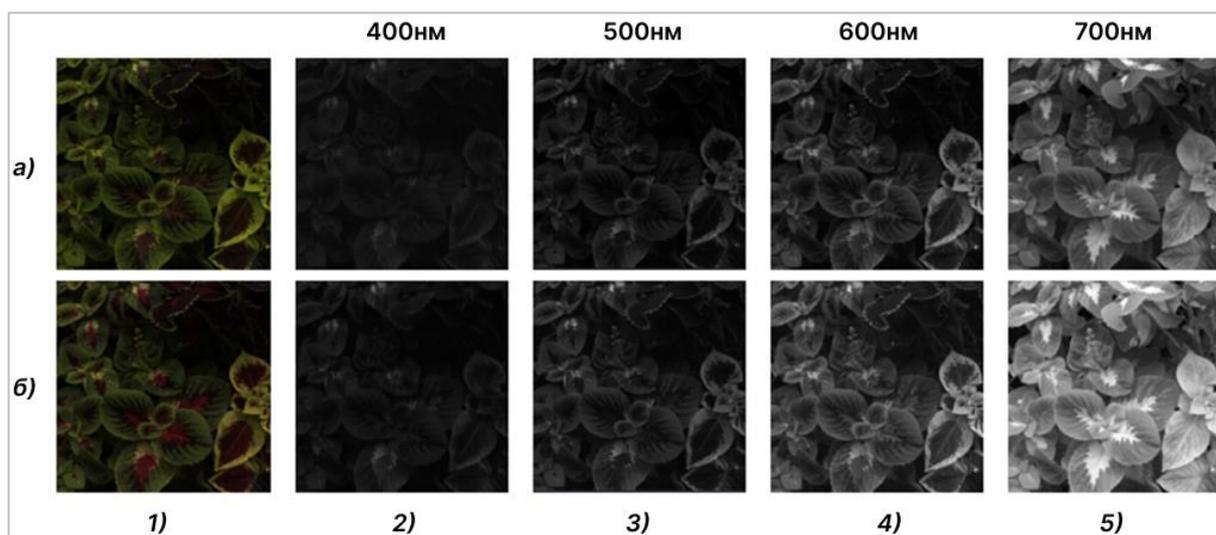
$$RGB = HS \times ResponseFunction. \quad (3.1)$$

Для набора «чистых» RGB-изображений данные были синтезированы из спектральных изображений с использованием стандартной функции отклика (Response Function), что позволяет точно соотнести каждую спектральную полосу с каналами R, G и B. Данный процесс представлен формулой (3.1), где HS — матрица гиперспектрального изображения размерностью $482 \times 512 \times 31$, $ResponseFunction$ — матрица размерностью 31×3 , содержащая параметры преобразования спектральных полос в три канала RGB. Функция отклика использует 93 параметра, что позволяет учесть вклад каждой спектральной полосы в соответствующий канал, обеспечивая точное представление цветовых характеристик. Такой подход обеспечивает совместимость гиперспектральных и RGB-данных.

Изображения сохраняются в несжатом формате, что исключает потерю качества содержащихся данных. Поскольку исходный набор не содержит значительных дефектов, а уровень шума на изображениях минимален, результаты, полученные при его использовании, демонстрируют эффективность алгоритма восстановления гиперспектральных характеристик без учета дополнительных методов предобработки.

В случае набора «реального мира» RGB-изображения были сформированы с использованием неизвестной функции отклика, что значительно усложняет задачу. Поскольку многополосные данные содержат 31 канал, а RGB-изображения — 3 канала, процесс восстановления гиперспектральной информации из данной коллекции требует учета как неопределенности процесса формирования данных, так и возможных искажений.

Обучающая выборка для обоих наборов данных включает 450 пар совмещенных RGB-изображений и соответствующих гиперспектральных данных, которые репрезентативно охватывают широкий диапазон различных сцен. Такой подход обеспечивает достаточное разнообразие обучающих примеров для повышения общей способности модели к генерализации. Примеры изображений из указанных наборов представлены на рисунке 3.1.



1a — RGB-изображение набора чистого мира, *1б* — RGB-изображение набора реального мира, *2a–5a* — гиперспектральные изображения набора чистого мира, *2б–5б* — гиперспектральные изображения набора реального мира

Рисунок 3.1 — Визуализация набора данных NTIRE 2020

Каждое гиперспектральное изображение содержит информацию по 31 спектральной полосе, охватывающей диапазон длин волн от 400 нм до 700 нм, что соответствует видимой части электромагнитного спектра. Выбор конкретного количества полос объясняется необходимостью точного представления спектральной информации при сохранении вычислительной эффективности. Данный интервал длин волн разделяется на равные части, что позволяет захватить ключевые особенности взаимодействия света с объектами сцены, включая их отражательные, поглотительные и преломляющие свойства.

Пространственное разрешение гиперспектральных изображений составляет 482×512 пикселей. Тем самым каждый образец предоставляет достаточно информации для анализа текстур и деталей сцены, сохраняя при этом приемлемые требования к объему памяти и вычислительным ресурсам.

3.3 Процесс обучения модели

Обучение модели HRNet проводилось на протяжении 10 000 эпох. Начальная скорость обучения была установлена на уровне 1×10^{-4} , с последующим поэтапным снижением в два раза каждые 3000 эпох. Подобная стратегия постепенного уменьшения темпа обучения направлена на достижение баланса между эффективностью начального обучения и стабильностью процесса оптимизации на поздних этапах. На начальных

стадиях высокая скорость обучения способствует быстрому снижению значения функции потерь, тогда как на более поздних этапах — ее уменьшение помогает избежать переобучения и смягчает колебания градиентов, обеспечивая более устойчивую сходимость.

В качестве алгоритма оптимизации параметров модели был выбран алгоритм Adam [28, 39]. Данный метод был выбран за его способность эффективно справляться с задачами, характеризующимися высокой размерностью пространства параметров, а также за его устойчивость при обучении на данных, подверженных шуму.

Параметры β_1 и β_2 в оптимизаторе определяют веса экспоненциального сглаживания для первого и второго моментов градиента. Обычно $\beta_1 \approx 0.9$, поскольку данное значение помогает усреднять градиенты и обеспечивает стабильность оптимизации. Более низкие значения β_1 (< 0.9) могут ускорить адаптацию оптимизатора на начальных этапах обучения за счет менее агрессивного сглаживания, однако выбор таких значений может привести к меньшей стабильности в дальнейшем.

Значение β_2 , как правило, полагают равным $\beta_2 \approx 0.999$, что соответствует значению сглаживания оценки второй производной. Большие, близкие к единице, значения способствуют плавности, но могут замедлять реакцию на изменения в данных.

С учетом специфики задачи и высокой степени искажения данных на начальных этапах обучения были выбраны значения параметров $\beta_1 = 0.5$ и $\beta_2 = 0.999$. Такой подход позволяет ускорить процесс обучения в начальной фазе, улучшая адаптацию модели к данным. Данная конфигурация обеспечивает баланс между скоростью сходимости и стабильностью оптимизации, что играет важную роль в обработке гиперспектральных изображений, характеризующихся сложностью структуры данных.

В разработанной архитектуре нейронной сети был установлен фиксированный размер входных изображений — 256×256 пикселей. Данный размер был выбран с учетом необходимости генерации нескольких фрагментов из одного и того же изображения, что позволяет повысить эффективность обучения за счет увеличения разнообразия обучающего набора. Формирование фрагментов осуществляется с использованием метода случайной обрезки (random cropping), который является одной из форм аугментации данных. Этот подход способствует моделированию различных участков сцены или точек зрения, тем самым повышая устойчивость модели к изменчивости входной информации и снижая риск переобучения.

Перед подачей в сеть изображения проходят процедуру нормализации, при которой значения пикселей приводятся к диапазону $[0, 1]$.

Все эксперименты проводились на двух графических процессорах NVIDIA GeForce RTX 3070 Ti. В условиях выбранной архитектуры и объема данных полный цикл обучения модели занял приблизительно 7 дней.

3.4 Стратегия объединения

Поскольку пространство решений задачи спектральной реконструкции может быть довольно большим, существует множество возможных конфигураций, которые обеспечивают схожую производительность на обучающем наборе данных. Чтобы уменьшить риск обобщения, применяется подход ансамблирования, использующая несколько моделей, каждая из которых обучается независимо. Результаты работы этих моделей затем агрегируются.

Для реализации стратегии ансамблирования вводится четыре дополнительных варианта гиперпараметров, в рамках которых модель HRNet обучается с нуля для каждого из двух треков:

1. Повторное обучение HRNet с базовыми настройками обучения.
2. Обучение сети с другим размером обрезаемых фрагментов (320×320 и 384×384) при сохранении остальных гиперпараметров и архитектуры сети.
3. Обучение сети с другим размером пакета (2 или 4) при сохранении остальных гиперпараметров и архитектуры сети.
4. Перестановку местами остаточного плотного блока и остаточного глобального блока в HRNet с сохранением базовых настроек обучения.

В результате получают 8 различных методов обучения. Все методы, используемые для ансамблирования, обучаются в течение 10 000 эпох.

$$MRAE = \frac{1}{N} \sum_{i=1}^N \frac{|G(x)^i - y^i|}{y^i}. \quad (3.2)$$

Каждые 1000 эпох фиксируется значение MRAE, которое демонстрирует среднее абсолютное отклонение между сгенерированными спектральными изображениями $G(x)$ и эталонными y . Числовое значение MRAE вычисляется по формуле (3.2), где N обозначает общее количество пикселей спектральных изображений.

Для RMSE вычисляется ошибка между сгенерированным спектральным изображением и истинным спектральным изображением земли, состоящим из 31 полосы.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (G(x)^i - y^i)^2}. \quad (3.3)$$

Численные вычисления среднеквадратичной ошибки представлены формулой (3.3).

$$BPMRAE = \frac{1}{N} \sum_{i=1}^N \frac{|R \times G(x)^i - (R \times y)^i|}{y^i}. \quad (3.4)$$

Значение BPMRAE — среднее абсолютное отклонение с обратной проекцией — оценивает колориметрическую точность восстановленных из RGB спектральных изображений и детализированных с помощью функции фиксированного отклика камеры. Данную величину можно определить по формуле (3.4), где R обозначает функцию отклика функции.

В таблице 3.1 приведены результаты сравнения различных архитектур.

Таблица 3.1 — Характеристики архитектур HRNet, U-Net и U-ResNet.

Метод	Набор данных	U-Net	U-ResNet	HRNet
MRAE	«Чистый» набор	0.047507	0.045242	0.042508
	Набор «Реальный мир»	0.074230	0.078892	0.071152
RMSE	«Чистый» набор	0.014154	0.013927	0.013537
	Набор «Реальный мир»	0.018647	0.020630	0.017859
BPMRAE	«Чистый» набор	0.007926	0.007171	0.006064
	Набор «Реальный мир»	0.044966	0.055876	0.042105

3.5 Оценка качества восстановления с помощью HRNet

Для проведения сравнительного анализа были выбраны несколько популярных архитектур нейронных сетей: U-Net [48], U-ResNet [48, 28], а также модель HSCNN-D, рассмотренная в предыдущем исследовании. Архитектуры U-Net и U-ResNet продемонстрировали высокую эффективность при решении ряда задач, связанных с низкоуровневой обработкой изображений, включая задачи сегментации и восстановления изображений [38, 30, 27].

В данных моделях применяется сверточная операция с ядром размером 7×7 в начальных и конечных слоях, при этом не происходит изменения пространственного разрешения выходных данных. Обучение всех рассматриваемых моделей проводится по одинаковой методике. В архитектуре U-Net в процессе кодирования используются сверточные операции размером 2, что ведет к постепенному снижению пространственного разрешения на каждом уровне сети. На самом нижнем уровне кодировщика пространство признаков имеет размер 1×1 . Между слоями кодера и декодера с одинаковым разрешением организованы краткосрочные соединения, что способствует улучшению пропуска информации на различных уровнях абстракции.

В отличие от U-Net, архитектура U-ResNet отличается уменьшенным числом слоев кодера и декодера, которые составляют половину от таковых в модели U-Net. В то же время к последнему слою кодера добавлены четыре остаточных блока, что способствует улучшению качества обучения и повышению способности модели к обобщению. Краткосрочные соединения между слоями, как и в модели U-Net, сохраняются, что также способствует лучшему захвату особенностей на разных уровнях.

Обучение трех моделей (U-Net, U-ResNet и HSCNN-D) проводилось с использованием одинаковых гиперпараметров, предварительно настроенных для сети HRNet, до достижения сходимости. Важно отметить, что стратегии ансамблирования в процессе обучения не применялись. Для оценки качества восстановленных спектральных изображений использовались результаты, полученные на наиболее успешной эпохе обучения. Итоговые результаты представлены в таблице 3.2. Первые три строки показывают распределение данных для трех рассматриваемых методов, в то время как последняя строка содержит эталонное изображение. Особое внимание следует уделить текстурам фона при проведении сравнительного анализа.

Таблица 3.2 — Сравнение рассматриваемых методов с предыдущими

Набор данных		Чистый	Реальный мир	Время выполнения (сек.)
Разреженное кодирование	MRAE	0.0816	-	112.933 (CPU)
	RMSE	49.217	-	
U-Net	MRAE	0.0756	-	16.57 (GPU)
	RMSE	17.006	-	
U-ResNet	MRAE	0.0582	0.0792	5.431 (GPU)
	RMSE	16.653	24.987	
HSCNN-D	MRAE	0.0495	0.0776	77.962 (GPU)
	RMSE	13.911	23.457	
HRNet	MRAE	0.0425	0.071152	3.748 (GPU)
	RMSE	0.013537	0.017859	

Преимущество предложенной архитектуры HRNet по сравнению с другими современными методами обработки изображений можно объяснить двумя основными факторами, которые значительно улучшают ее способность к извлечению признаков и повышают общую эффективность модели.

Во-первых, HRNet использует технологию PixelShuffle для соединения различных уровней сети, что позволяет более точно интегрировать информацию с различных масштабов. В отличие от традиционных методов, таких как ближайшее соседство или билинейная интерполяция, которые могут вносить избыточные и менее значимые данные, PixelShuffle обеспечивает более эффективную передачу информации между уровнями сети, минимизируя потерю существенных признаков. В сочетании с операцией PixelUnShuffle, данная методика позволяет HRNet точно восстанавливать и преобразовывать высокоуровневые признаки, способствуя улучшению качества извлечения характеристик и повышению точности модели.

Во-вторых, HRNet включает два блока, основанных на остаточном обучении, что значительно улучшает процесс сходимости модели и позволяет ей более эффективно работать с признаками на различных уровнях абстракции. Остаточные блоки способствуют более глубокому обучению сети, предотвращая проблему затухающих градиентов и улучшая способность сети анализировать сложные и многослойные паттерны в изображениях. Кроме того, остаточный глобальный блок HRNet усиливает контекстную

информацию, моделируя корреляции между пикселями на различных участках изображения. Что позволяет сети более эффективно учитывать взаимосвязи между элементами изображения и обеспечивать точные предсказания даже в сложных условиях.

3.6 Извлечение значений интенсивности с помощью деконволюции

В основе метода деконволюции лежит предположение, что каждый спектр можно аппроксимировать линейной комбинацией нескольких «чистых» компонент, соответствующих определенным длинам волн или опорным векторам в цветовом пространстве. Исходя из этого, RGB-изображение рассматривается как результат линейной смеси вкладов этих компонент. Задача заключается в том, чтобы вычислить их долю в каждом пикселе. В предложенном подходе решение реализуется через определение набора базисных векторов, полученных из спектральной модели цветового пространства, их ортогонализацию методом Грама-Шмидта и последующую проекцию изображения на этот базис [13]. Таким образом, на каждом шаге производится декомпозиция изображения по определенному направлению, что позволяет оценить его вклад в итоговый спектр.

Главным преимуществом такого подхода является его интерпретируемость. В отличие от методов, использующих нейронные сети, цветовая деконволюция не требует большого объема данных для обучения и не зависит от специфики конкретной архитектуры. Метод работает напрямую с физически осмысленными величинами, опираясь на цветовые модели и принципы линейной алгебры. Кроме того, поскольку деконволюция не использует аппроксимации, присущие нейросетям, она может быть применима к широкому классу изображений, даже без учета особенностей конкретной камеры или сцены.

Однако рассматриваемый метод имеет серьезные ограничения. Прежде всего, его точность напрямую зависит от качества базисных векторов и от используемой цветовой модели. Любая неточность в моделировании отклика сенсоров или искаженные входные данные приведут к ошибкам в деконволюции. Метод также чувствителен к шуму и может давать нестабильные результаты на изображениях с низкой контрастностью или ярко выраженными тенями. Поскольку реконструкция спектра выполняется отдельно для каждой длины волны, метод не учитывает взаимосвязи между соседними спектральными компонентами, что может привести к локальным

разрывам в непрерывности спектра. Стоит отметить, что метод также предполагает линейность откликов сенсоров камеры, что не всегда соблюдается на практике, особенно в случае JPEG-файлов и автоматической обработки изображений в фотокамерах.

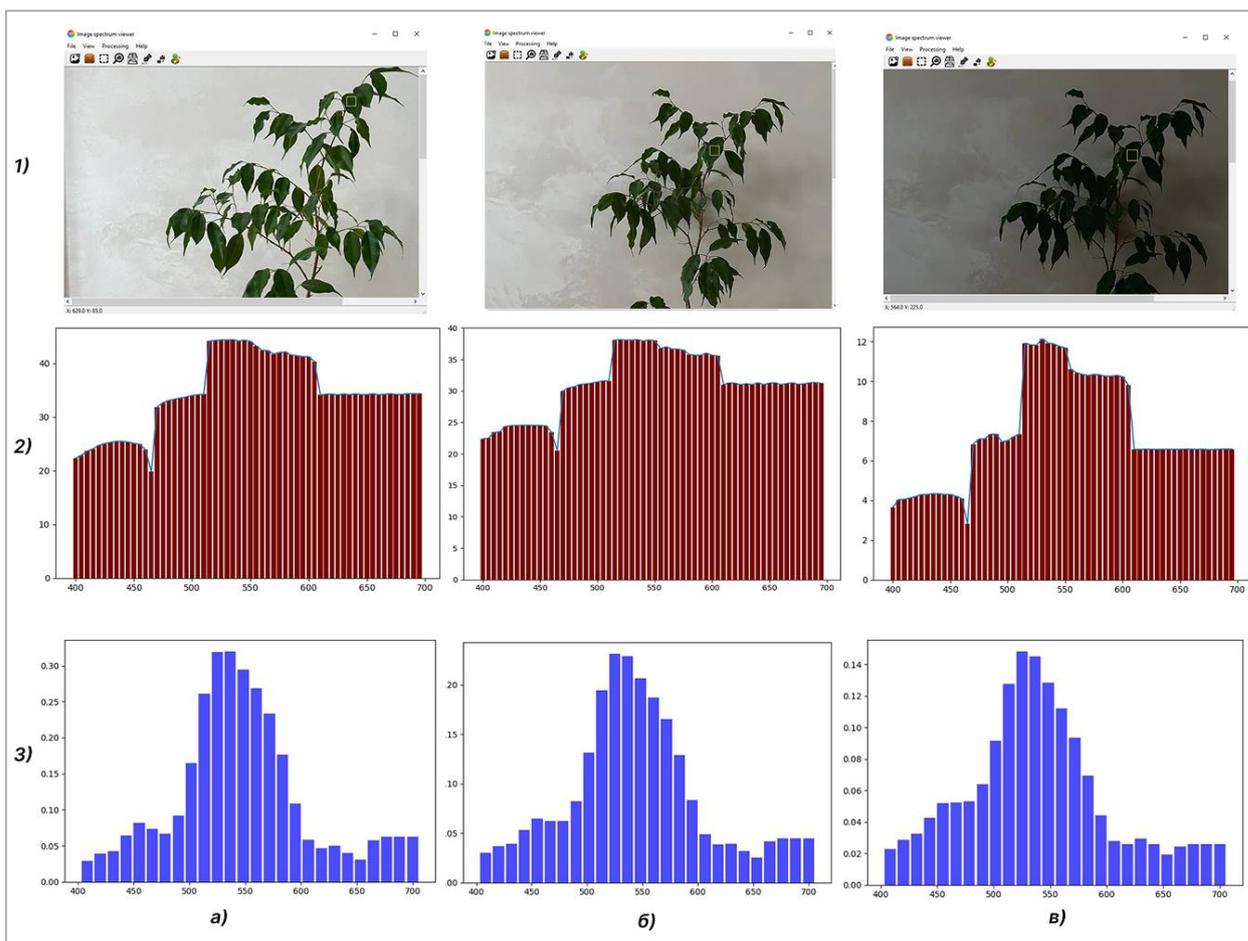
Данный подход может давать существенные ошибки, если один и тот же объект будет обрабатываться при разном освещении. Так как RGB-изображения фиксируют интегральный результат взаимодействия трех факторов — собственного спектра отражения объекта, спектра освещения и спектральной чувствительности сенсоров камеры. Когда освещение меняется, изменяется и форма зафиксированного сигнала, даже если объект остается тем же самым. На рисунке 3.2 представлены фотографии комнатного растения в разное время суток: утром, днем и вечером.



а — мягкий рассеянный свет, *б* — яркое естественное освещение, *в* — естественное освещение без использования искусственного света

Рисунок 3.2 — Влияние освещения на внешний вид комнатного растения

Цветовая деконволюция не учитывает спектр источника света, то есть воспринимает вариации в освещении как изменение самого объекта. Это может привести к смещению в реконструированных спектрах, особенно если освещение резко отличается по цветовой температуре или по интенсивности. Результаты восстановления спектрального отражения с помощью метода деконволюции и результат, полученный с использованием нейронной сети, восстанавливающей цветовые характеристики без учета освещения, представлены на рисунке 3.3. Сравнение демонстрирует различия в точности и детализации при изменении освещения объекта на изображении.



1a–1в — исходные изображения, *2a–2в* — спектральные графики, полученные методом деконволюции, *3a–3в* — спектральные графики, полученные с помощью нейронной сети
Рисунок 3.3 — Результаты восстановления спектральных характеристик растения с использованием различных методов

Таким образом, цветовая деконволюция является ценным инструментом для восстановления спектральной информации, особенно в условиях ограниченности данных и при необходимости физической интерпретируемости. Однако требования к съемке существенно ограничивают возможности применения метода деконволюции в реальных условиях, особенно в ситуациях с переменными или слабо контролируемыми параметрами окружающей среды. На практике она может использоваться как самостоятельный метод или как предварительный шаг в более сложных гибридных системах, включающих статистические или машинно-обучающие компоненты.

3.7 Программная реализация методов построения спектральных графиков

С целью исследования результатов восстановления спектральных данных, а также оценки эффективности выбранных подходов, в рамках данной работы было разработано программное обеспечение. Основной функционал приложения заключается в интерактивном получении графиков, отображающих распределение интенсивности сигнала по длинам волн, на основе заданной пользователем области интереса. Логика работы программного модуля, отражающая выбор метода восстановления спектра и последовательность этапов обработки изображения, представлена в виде блок-схемы на рисунке 3.4.

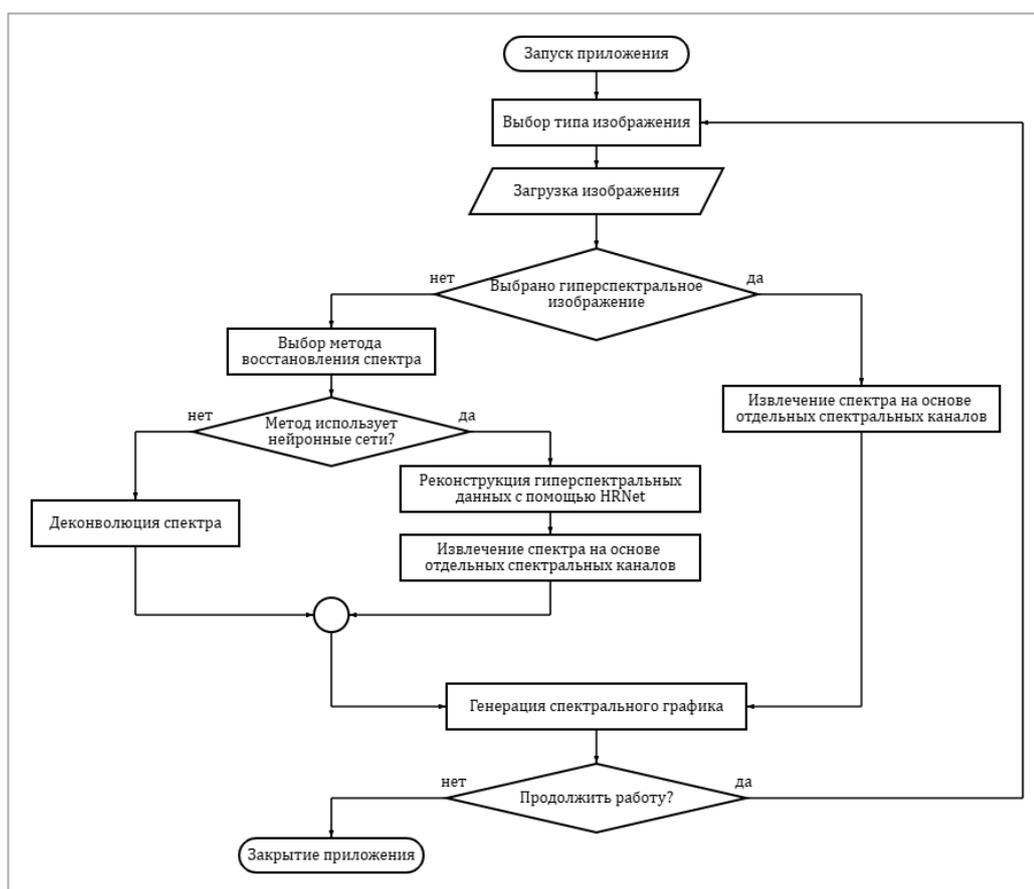


Рисунок 3.4 — Блок-схема пользовательской части приложения

Разработанная программа поддерживает два формата входных данных: стандартные RGB-изображения и гиперспектральные изображения, сохраненные в формате RAW. В процессе тестирования выбранных методов формирования спектральных данных использовались изображения, полученные с помощью полнокадровой гиперспектральной камеры Muses9-

HS, что позволило провести оценку эффективности реализованных алгоритмов. На рисунке 3.5 приведен пример изображений, полученных с его помощью.

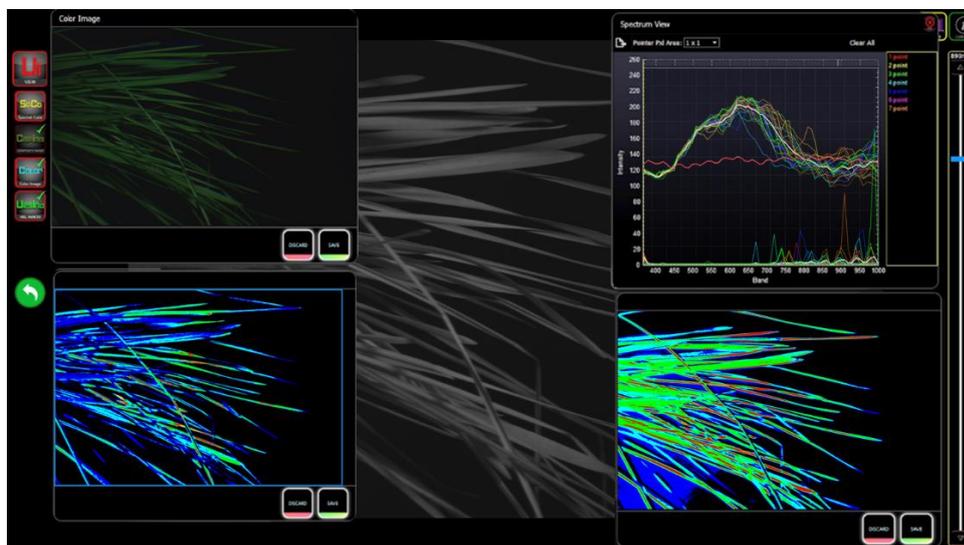


Рисунок 3.5 — Пример изображений, полученных с использованием Muses9-HS

На рисунке 3.6 представлен спектр, полученный на основе гиперспектрального изображения, захваченного камерой Muses9-HS. Видно, что спектр обладает сглаженной, плавной формой без выраженных резких скачков или аномальных пиков, что указывает на высокое качество исходных данных и отсутствие значительных шумов или артефактов.

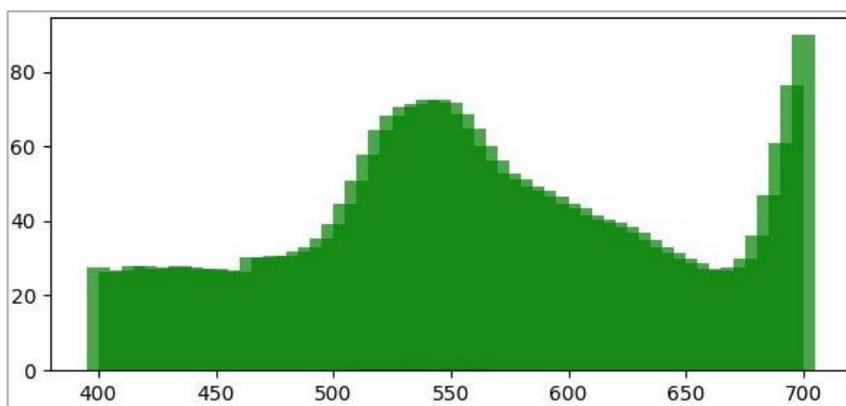


Рисунок 3.6 — Пример спектрального графика, построенного на основе реального гиперспектрального изображения

Спектральная кривая охватывает диапазон длин волн приблизительно от 400 до 720 нм, при этом наблюдаются два выраженных участка: умеренное плато в диапазоне 520–580 нм, соответствующее зеленой части спектра, и постепенное возрастание интенсивности в красной области ближе к 700 нм. Также можно отметить относительно равномерное распределение

интенсивности в синей части спектра (400–500 нм), что указывает на сбалансированную чувствительность камеры по всему видимому диапазону.

Обработка изображений, полученных с использованием стандартных цифровых камер, реализована в двух различных режимах. Независимо от выбранного режима, на предварительном этапе выполняется преобразование цветового пространства: изображения, как правило, импортируются в формате BGR, и преобразуются в формат RGB. Данное преобразование является необходимым условием для последующих этапов спектральной обработки и обеспечивает соответствие формата входных данных требованиям реализованных алгоритмов.

Далее в зависимости от целей исследования определяется метода анализа изображения. В случае применения нейронных сетей, используется предварительно обученная модель HRNet. На следующем шаге из каждого спектрального канала реконструированного изображения извлекаются значения интенсивности, по которым строится спектр исследуемой области. Затем формируется приближенное гиперспектральное представление сцены.

На рисунке 3.7 представлен спектр, полученный с использованием нейронной сети. Результаты реконструкции продемонстрировали высокую способность модели к восстановлению спектрального распределения интенсивности. Восстановленные данные хорошо воспроизводят форму спектра, включая характерный пик в диапазоне 530–560 нм, который соответствует реальным спектральным характеристикам источника. Несмотря на снижение абсолютных значений интенсивности — примерно в два раза по сравнению с эталонным спектром — относительное распределение сохраняется с высокой точностью. Стоит отметить, что нейросетевой метод не требует строгого соблюдения условий съемки, поэтому демонстрирует более высокую гибкость и применимость в реальных, слабо контролируемых условиях.

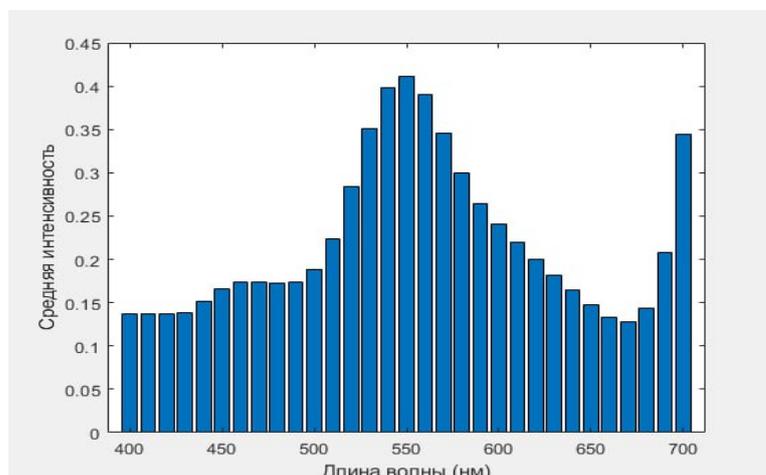


Рисунок 3.7 — Пример спектрального волна графика, полученного с HRNet

Альтернативным вариантом является использование метода деконволюции, в частности алгоритма Руифрока-Джонстона. В этом случае спектральный график формируется посредством численного восстановления спектра на основе известных характеристик отклика камеры и предполагаемого состава интенсивности сцены. Однако при таком подходе были утеряны детали за пределами основного диапазона — края спектра имеют завышенную интенсивность.

На выходе метод возвращает одномерный массив спектра. Нормализованные данные визуализируются в виде комбинированного графика — одновременно отображаются как линейная, так и столбчатая диаграммы.

Диапазон длин волн охватывает видимую часть спектра — от 400 до 700 нм. Пример полученных результатов представлен на рисунке 3.8.

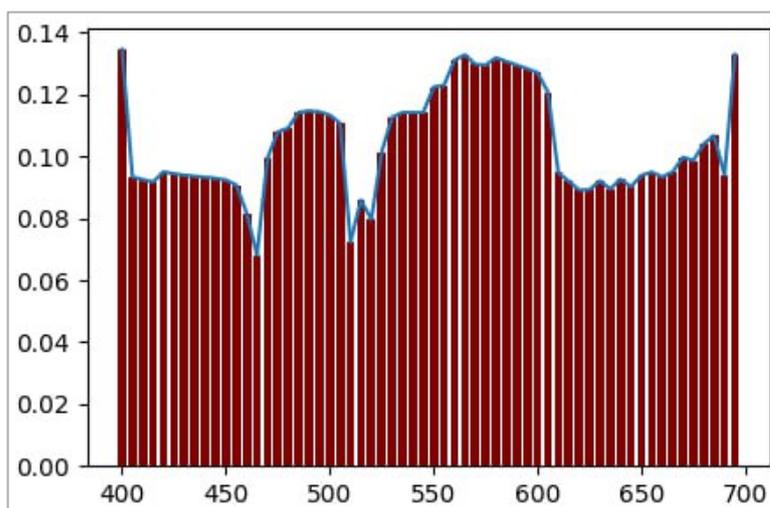


Рисунок 3.8 — Пример спектрального графика, полученного с помощью деконволюции

После завершения всех операций интерфейс автоматически переключается в режим отображения графика, и пользователь может проанализировать результат. Таким образом, приложение позволяет быстро и удобно получать спектральные характеристики изображения, что делает его полезным инструментом для визуального и количественного анализа.

3.8 Выводы

В ходе исследования были рассмотрены два подхода к генерации спектральных графиков: восстановление гиперспектральных изображений с дальнейшим извлечением интенсивностей по каждому каналу и метод деконволюции цвета. Сравнение производилось с эталонным спектром, полученным с гиперспектральной камеры Muses9-HS.

Результаты, полученные с помощью сверточная нейронная сеть на базе архитектуры HRNet, показали, что модель способна достаточно точно воспроизводить форму распределения интенсивности по длинам волн. Несмотря на некоторую потерю деталей на краях спектра, форма сигнала сохраняется.

Метод деконволюции показал свою эффективность в восстановлении формы спектра. Однако на точности его работы сказывалась сильная зависимость от условий съемки. При отсутствии информации о параметрах освещения результаты восстановления отличались выраженной резкостью переходов между длинами волн и слабовыраженными крайними значениями. Поэтому на выходе получались существенные искажения формы от эталонного спектра. Такие результаты указывают на высокую чувствительность метода к внешним условиям. Для достижения достоверных результатов требуется точное знание функции свертки, а также строгое соблюдение условий проведения измерений — в частности, обеспечение стабильного, однородного и хорошо контролируемого освещения.

Таким образом, в ходе работы был проведен анализ существующих методов извлечения спектральных данных. В результате предложен подход, основанный на восстановлении гиперспектральных данных с последующим извлечением интенсивностей.

ЗАКЛЮЧЕНИЕ

В рамках дипломной работы проведено исследование возможности восстановления спектральной информации на основе стандартных RGB-изображений. Были выполнены эксперименты в различных условиях освещения с последующим анализом влияния этих условий на точность генерации спектральных графиков.

В ходе работы была реализована архитектура нейронной сети HRNet. Извлеченные значения интенсивностей из реконструированных изображений продемонстрировали высокую точность восстановления спектральной информации. Модель успешно сохранила форму спектров практически на всем рассматриваемом диапазоне длин волн. Совпадение положений спектральных пиков с эталонными данными подтверждает достоверность полученных результатов.

Для сравнения был также протестирован метод деконволюции, который при определенных условиях обеспечивает удовлетворительные результаты. Однако высокая чувствительность к освещению и необходимость точного знания характеристик съемки серьезно ограничивают применимость данного подхода в реальных условиях.

Проведенный сравнительный анализ спектральных данных, полученных с помощью гиперспектральной камеры и восстановленных из RGB-снимков, подтвердил, что подход с применением нейронных сетей обеспечивает более устойчивое и адаптивное решение. Таким образом, использование гиперспектральных изображений для восстановления спектральной информации является наиболее перспективным методом в задачах мониторинга состояния растений, обеспечивая необходимую точность при меньших затратах и более высокой гибкости в реальных условиях.

Полученные результаты позволяют достичь поставленной цели — определить наиболее эффективный метод мониторинга состояния растений.

Основные положения дипломной работы были апробированы в рамках 67-мой Всероссийской научной конференции МФТИ, что подтверждает их научную состоятельность. Тезисы к работе опубликованы в сборнике трудов МФТИ, секция «Алгоритмы и технологии программирования». Тезисы и список участников доступны на официальном сайте факультета ФПМИ, секции «Проблемы интеллектуального анализа данных, распознавания и прогнозирования» [3].

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Алиева, Н. З. Физика цвета и психология зрительного восприятия / Н. З. Алиева // учеб. пособие для студ. высш. учеб. заведений — М.: Издательский центр «Академия». — 2008. — 208 с.
2. Василенко, Г. И. Восстановление изображений / Г. И. Василенко, А. М. Тараторин // Научная библиотека [Электронный ресурс] — Радио и связь, 1986. — 304 с. — URL: https://scask.ru/i_book_recimg.php (дата обращения: 24.10.2024).
3. Всероссийская 67-я конференция МФТИ. Факультет ФПМИ, секция «Проблемы интеллектуального анализа данных, распознавания и прогнозирования» [Электронный ресурс]. — URL: https://conf.mipt.ru/view/conference/view_division/3511931 (дата обращения: 19.04.2025).
4. Вудс, Р. Цифровая обработка изображений / Р. Вудс, Р. Гонсалес // Studizba [Электронный ресурс] — Москва: Техносфера, 2012. — 1104 с. — URL: <https://studizba.com/files/show/pdf/84807-1-gonsales-r-vuds-r-cifrovaya-obrabotka.html> (дата обращения: 24.10.2024).
5. Гиперспектральная визуализация. Что это и где применяется? // АО «ЛЛС» [Электронный ресурс]. — 2023. — URL: <https://lenlasers.ru/novosti-i-stati/giperspektralnaya-vizualizatsiya-cto-eto-i-gde-primenyaetsya> (дата обращения: 10.10.2024).
6. Горбунова, Е.В. Типовые расчеты по колориметрии источников излучения / Е.В. Горбунова, А. Н. Чертов // Учебное пособие. — СПб: Университет ИТМО, 2014. — с. 9–20.
7. Документация NumPy; numpy.org [Electronic resource]. — <https://numpy.org/doc/stable>.
8. Документация PyTorch; pytorch.org [Electronic resource]. — <https://pytorch.org>.
9. Документация SciPy; scipy.org [Electronic resource]. — <https://docs.scipy.org/doc/scipy>.
10. Документация TensorFlow; tensorflow.org [Electronic resource]. — <https://www.tensorflow.org>.
11. Ермаков, В. В. Классификация гиперспектральных изображений с использованием кластерной структуры данных / В.В. Ермаков, М.П. Кузнецов, Е.В. Раменская // Современные проблемы дистанционного зондирования Земли из космоса / СГТУ, Самара, Россия. — 2017 — URL: http://d33.infospace.ru/d33_conf/sb2017t7/9-19.pdf (дата обращения: 17.09.2024).

12. Ковалева, И. Получение и обработка изображений / И. Ковалева // Научная библиотека [Электронный ресурс] — Минск, 2008. — 17 с. — URL: https://www.iae.nsk.su/images/stories/4_Education/3_DisSovet/221220/%D0%9F%D1%80%D0%BE%D0%BD%D0%B8%D0%BD%D0%B0/%D0%94%D0%B8%D1%81%D1%81%D0%B5%D1%80%D1%82%D0%B0%D1%86%D0%B8%D1%8F_%D0%9F%D1%80%D0%BE%D0%BD%D0%B8%D0%BD%D0%B0%D0%92%D0%A1_compressed.pdf (дата обращения: 13.04.2025).
13. Констандогло, А. Методы восстановления расфокусированных и смазанных изображений/ А. Констандогло // Научная библиотека [Электронный ресурс] — МГТУ им. Н.Э. Баумана, Москва, 2020. — 6–9 с. — URL: <https://ptsj.bmstu.ru/articles/612/612.pdf> (дата обращения: 13.04.2025).
14. Люлин, О. М. Определение параметров спектральных линий из нескольких спектров поглощения с помощью программы MultiSpectrum Fitting / О. М. Люлин // Институт оптики атмосферы имени В. Е. Зуева СО РАН, «Оптика атмосферы и океана» 28 — 2015. — №5. — с. 408–412.
15. Мониторинг растений по изменению цвета / А. В. Креч; БГУ — Минск, 2024. — с. 14 – 21.
16. Определение спектральных характеристик области на фрагменте RGB изображения для оценки развития растений / М.А. Недзьведь, А.А. Недзьведь; Электронная библиотека БГУ [Электронный ресурс]. — URL: <https://elib.bsu.by/bitstream/123456789/288539/1/189-196.pdf> (date of access: 21.09.2024).
17. Пронина, В. Восстановление изображений с помощью обучаемых оптимизационно-нейросетевых алгоритмов / В. Пронина // Научная библиотека [Электронный ресурс] — ИАиЭ СО РАН, 2022. — 14–16 с. — URL: https://scask.ru/i_book_recimg.php (дата обращения: 24.10.2024).
18. Тихонов, А. Н. Методы решения некорректных задач / А. Н. Тихонов [и др.] // Научная библиотека [Электронный ресурс] — Издание 2-е. — Наука, 1979 — URL: <https://www.klex.ru/181u> (дата обращения: 24.04.2024).
19. 2D-3D CNN Based architectures for spectral reconstruction from RGB images / S. Koundinya, et al.; Content CVPR [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018. — URL: https://openaccess.thecvf.com/content_cvpr_2018_workshops/papers/w13/Koundinya_2D-3D_CNN_Based_CVPR_2018_paper.pdf (date of access: 14.10.2024).
20. Atkins, P. Physical Chemistry / P. Atkins, J. Paula // Rnlkwc.ac.in [Electronic resource]. — Oxford, 2006 — p. 504–507 — URL: <https://rnlkwc.ac.in/pdf/study-materi->

- [al/chemistry/Peter_Atkins_Julio_de_Paula_Physical_Chemistry_1_.pdf](#)
(date of access: 22.09.2024).
21. Berger, K. Evaluation of the PROSAIL Model Capabilities for Future Hyperspectral Model Environments: A Review Study / K. Berger // MPDI. 2018.
 22. Can, Y. B. An efficient CNN for spectral reconstruction from RGB images / Y. B. Can, R. Timofte // Arxiv [Electronic resource]. — IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017 — URL: <https://arxiv.org/pdf/1804.04647> (date of access: 22.10.2024).
 23. CANNA: The solution for growth and bloom [Electronic resource] — / Ed. K.A. Kroeze. — BMS Lab., 2009. — URL: <https://www.cannagardening.com/articles/influence-colors-plants> (date of access: 22.03.2025).
 24. Clegg, M. T. Flower color variation: A model for the experimental study of evolution / M. T. Clegg, M. L. Durbin // Department of Botany and Plant Sciences, University of California, Riverside. — 2000. — Vol. 97. — P. 7016–7023.
 25. CNN-based hyperspectral image recovery from spectrally undersampled projections / Z. Xiong [et al.]; Content CVPR [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017 — URL: https://openaccess.thecvf.com/content_ICCV_2017_workshops/papers/w9/Xiong_HSCNN_CNN-Based_Hyperspectral_ICCV_2017_paper.pdf (date of access: 25.10.2024).
 26. Czyż, P. Python Deconvolution / P. Czyż // ReadTheDocs. — 2018. — URL: <https://deconvolution.readthedocs.io/en/latest/readme.html#id14> (date of access: 11.05.2025).
 27. DeblurGAN: Blind Motion Deblurring Using Conditional Adversarial Networks / O. Kupyn [et al.]; Arxiv [Electronic resource]. — Visual Recognition Group, Center for Machine Perception, 2018 — URL: <https://arxiv.org/pdf/1711.07064> (date of access: 29.11.2024).
 28. Deep residual learning for image recognition / K. He [et al.]; ieeexplore [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018 — URL: <https://ieeexplore.ieee.org/document/7780459> (date of access: 26.10.2024).
 29. Hadamard, J. Sur les Problemes Aux Derivees Partielles et Leur Signification Physique / J. Hadamard // Princeton university bulletin. — 1902. — c. 49–52. — URL: <https://illposed.net/hadamard.pdf> (date of access: 16.04.2024).
 30. Hierarchical Regression Network for Spectral Reconstruction from RGB Images / Y. Zhao [et al.]; Content CVPR [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2020 — URL:

- https://openaccess.thecvf.com/content_CVPRW_2020/papers/w31/Zhao_Hierarchical_Regression_Network_for_Spectral_Reconstruction_From_RGB_Images_CVPRW_2020_paper.pdf (date of access: 01.12.2024).
31. HSCNN+: Advanced CNN-Based Hyperspectral Recovery from RGB Images / Z. Shi [et al.]; Content CVPR [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018 — URL: https://openaccess.thecvf.com/content_cvpr_2018_workshops/papers/w13/Shi_HSCNN_Advanced_CNN-Based_CVPR_2018_paper.pdf (date of access: 25.10.2024).
 32. Huang, G. Densely Connected Convolutional Networks / G. Huang, L. Zhuang, L. Maaten — Arxiv [Electronic resource]. — In Proceedings of the International Conference on Learning Representations, 2018 — URL: <https://arxiv.org/pdf/1608.06993> (date of access: 02.10.2024).
 33. Huang, J. Practical Considerations on PAT Analyzer Selection - Raman vs. NIR Spectroscopy / J. Huang, S. Romero-Torres, M. Moshgbar // American Pharmaceutical Review, 2010 — P. 116–127. URL: <https://www.americanpharmaceuticalreview.com/Featured-Articles/117780-Practical-Considerations-on-PAT-Analyzer-Selection-Raman-vs-NIR-Spectroscopy/> (date of access: 04.04.2025).
 34. Hybrid Pixel-Unshuffled Network for Lightweight Image Super-Resolution / B. Sun [et al.]; Arxiv [Electronic resource]. — Northeastern University, Boston, MA, USA — URL: <https://arxiv.org/pdf/2203.08921> (date of access: 26.10.2024).
 35. Hyperspectral Imaging for Ubiquitous Computing Applications / T. S. Saponas [et al.] // DUB Group University of Washington, Seattle — URL: <https://ubicomplab.cs.washington.edu/pdfs/hypercam.pdf> (date of access: 12.09.2024).
 36. Hyperspectral Imaging in Agriculture, Food and Environment / L. Xiaona [et al.]; under the general editorship of I. L M. Alejandro. — United Kingdom: IntechOpen, 2018. — P. 17.
 37. Hyperspectral remote sensing data analysis and future challenges / J.M. Bioucas-Dias [et al.]; Geoscience and Remote Sensing Magazine. — 2013. — Vol. 1, № 2. — P. 6–36.
 38. Image-to-Image Translation with Conditional Adversarial Networks / P. Isola [et al.]; Content CVPR [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017 — URL: https://openaccess.thecvf.com/content_cvpr_2017/papers/Isola_Image-To-Image_Translation_With_CVPR_2017_paper.pdf (date of access: 01.12.2024).

39. Kingma, D. P. Adam: a method for stochastic optimization / D. P. Kingma, J. Lei Ba — Arxiv [Electronic resource]. — In Proceedings of the International Conference on Learning Representations, 2017 — URL: <https://arxiv.org/pdf/1412.6980> (date of access: 12.11.2024).
40. Ledig, C. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network / C. Ledig [et al.] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2017. — c. 105 — 114. — URL: <https://ieeexplore.ieee.org/document/8099502> (date of access: 16.10.2024).
41. Lewis, J. Forensic Document Examination. Fundamentals and Current Trends / J. Lewis // The American Academy of Forensic Sciences / Sciencedirect [Electronic resource]. — Academic Press, 2014 — URL: <https://www.sciencedirect.com/book/9780124166936/forensic-document-examination> (date of access: 12.09.2024).
42. Ludas, A. Metamerism problem in the colour recipe calculation / A. Ludas, M. Gloger; IOP Conference Series: Earth and Environmental Science. — 2024. — Vol. 1380. — P. 2–3.
43. MLIFeat: Multi-level information fusion based deep local features / Y. Zhang [et al.]; ResearchGate [Electronic resource]. — Computer Vision – ACCV, 2021. — p. 403–419 — URL: https://www.researchgate.net/publication/349580000_MLIFeat_Multi-level_Information_Fusion_Based_Deep_Local_Features (date of access: 26.10.2024).
44. Pauli, D.W. The Quest for Understanding Phenotypic Variation via Integrated Approaches in the Field Environment / D.W. Pauli, S. C. Chapman, C. N. Topp // Plant Physiology. — 2016. — Vol. 172. — P. 622–663.
45. Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network / W. Shi [et al.]; Arxiv [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2016 — URL: <https://arxiv.org/pdf/1609.05158> (date of access: 26.10.2024).
46. Reconstructing spectral images from RGB-images using a convolutional neural network / T. Stiebel [et al.]; Content CVPR [Electronic resource]. — In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018 — URL: https://openaccess.thecvf.com/content_cvpr_2018_workshops/papers/w13/Stiebel_Reconstructing_Spectral_Images_CVPR_2018_paper.pdf (date of access: 15.10.2024).
47. Rectifier Nonlinearities Improve Neural Network Acoustic Models / A. L. Maas [et al.]; Stanford.edu [Electronic resource]. — Computer Science Department, Stanford University, CA, USA, 2013 — URL:

- https://ai.stanford.edu/~amaas/papers/relu_hybrid_icml2013_final.pdf (date of access: 31.10.2024).
48. Ronneberger, O. U-net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox. — Arxiv [Electronic resource]. — In International Conference on Medical Image Computing and Computer-assisted Intervention, 2015 — URL: <https://arxiv.org/pdf/1412.6980> (date of access: 23.11.2024).
49. Ruifrok, A. C. Quantification of histochemical staining by color deconvolution / A. C. Ruifrok, D. A. Johnston; ResearchGate [Electronic resource]. — 2001. — P. 291–299. — URL: https://www.researchgate.net/publication/11815294_Ruifrok_AC_Johnston_D_A_Quantification_of_histochemical_staining_by_color_deconvolution_Anal_Quant_Cytol_Histol_23_291-299 (date of access: 06.05.2025).
50. Wang, L. Adaptive Nonlocal Sparse Representation for Dual-Camera Compressive Hyperspectral Imaging / L. Wang. // Arxiv [Electronic resource]. — IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017 — URL: <https://ieeexplore.ieee.org/document/7676344> (date of access: 12.10.2024).
51. Xavier, G. Understanding the difficulty of training deep feedforward neural networks / G. Xavier, B. Yoshua — In Proceedings of the thirteenth international conference on artificial intelligence and statistics. — 2010 — p. 249–256.