

На правах рукописи



АРУСТАМЯН ВАЛЕНТИНА АЛЕКСАНДРОВНА

МЕТОДЫ И АЛГОРИТМЫ ИНТЕЛЛЕКТУАЛЬНОЙ ОБРАБОТКИ
ИЗОБРАЖЕНИЙ В ЗАДАЧАХ ТОЧНОГО ЗЕМЛЕДЕЛИЯ

Специальность: 2.3.1 – Системный анализ, управление и обработка информации,
статистика (технические науки)

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
кандидата технических наук

Ставрополь – 2026

Работа выполнена в Федеральном государственном автономном
образовательном учреждении высшего образования
«Северо-Кавказский федеральный университет»

Научный руководитель: **Ляхов Павел Алексеевич**
кандидат физико-математических наук, доцент

Официальные оппоненты: _____

Ведущая организация: _____

Защита состоится _____ г. в _____ часов на заседании диссертационного
совета 24.2.398.02 при ФГАОУ ВО «Северо-Кавказский федеральный университет»
по адресу: 355017, г. Ставрополь, Пушкина 1, корпус __, ауд. ____.

С диссертацией можно ознакомиться в Научной библиотеке СКФУ по адресу:
355029, г. Ставрополь, пр. Кулакова 2 и на сайте СКФУ: _____

С авторефератом можно ознакомиться на сайте СКФУ: _____

Автореферат разослан «__» _____ 2026 г.

Ученый секретарь диссертационного совета,
доктор физико-математических наук, профессор

Г.В. Шагрова

Общая характеристика работы

Актуальность работы. В условиях усиления климатической нестабильности и роста потребностей в продовольственной безопасности обеспечение непрерывного мониторинга состояния сельскохозяйственных культур приобретает критическую значимость для систем точного земледелия. Для решения данной задачи широкое применение находят данные дистанционного зондирования Земли, в частности мультиспектральные снимки спутника Sentinel-2, обеспечивающие регулярную съёмку с высоким пространственным и временным разрешением. На их основе рассчитывается нормализованный разностный вегетационный индекс (Normalized Difference Vegetation index, NDVI) – ключевой показатель фотосинтетической активности и стрессовых состояний растительности. Однако практическое использование оптических данных сопряжено с фундаментальным ограничением, а именно частота облачности в вегетационный период умеренных широт достигает 30-40%, что приводит к систематическим пропускам во временных рядах и потере критически важной информации в ключевые фенологические фазы развития культур.

Для компенсации пропусков данных в настоящее время применяются промышленные платформы, такие как EOS Crop Monitoring и «Агросигнал», и научные методы реконструкции, например, HANTS, фильтры Савицкого-Голея и алгоритмы машинного обучения. Однако анализ их эффективности выявляет существенные ограничения. Большинство подходов опираются на временную интерполяцию или алгоритм формирования композитных изображений с отбором пикселей по максимальному значению вегетационного индекса, что приводит к задержке актуальной информации на 5-10 дней и не учитывает физиологический контекст состояния растений. Кроме того, существующие алгоритмы часто игнорируют локальные метеорологические условия, оценивают точность по всему кадру, искусственно завышая метрики за счёт ясных участков, либо используют данные глобального реанализа с грубым пространственным разрешением в 27 км, нивелирующим микроклиматические особенности конкретных полей.

В результате формируется научно-практическое противоречие между потребностью агробизнеса в непрерывных, физиологически достоверных временных рядах вегетационных индексов высокого разрешения и ограниченными возможностями существующих подходов, не способных обеспечить объективную реконструкцию NDVI непосредственно в зонах, закрытых облачным покровом. Разрешение данного противоречия требует перехода от эмпирической математической интерполяции к физически обоснованному мультимодальному синтезу данных, интегрирующему спектрально-временной контекст спутниковых снимков и локальные метеонаблюдения на уровне глубокого обучения. Именно необходимость разработки такого подхода, обеспечивающего высокую точность восстановления при сохранении пространственной структуры растительного

покрова, определяет высокую теоретическую и прикладную актуальность настоящего диссертационного исследования.

Значительный вклад в развитие методов реконструкции вегетационных индексов, восстановления спутниковых изображений и мультимодального слияния данных дистанционного зондирования внесли многие отечественные и зарубежные исследователи. Работы С. А. Барталева, Д. А. Бочарова, Е. А. Бочкаревой, В. Ф. Коновалова, Т. В. Руссковой, А. С. Степанова, А. В. Тарасова, Е. А. Шурлаевой, M. Belgiu, Y. Chen, D. Chu, F. Gao, K. He, A. Hollstein, P. Jonsson, Y. Julien, J. Li, S. Li, R. Liu, D. López-Puigdollers, H. Tamiminia, Q. Wang, D. J. Weiss, J. Xiao и Q. Zhang посвящены интерполяции временных рядов, детекции облачных образований, нейросетевому прогнозированию растительных индексов, а также вносят вклад в разработку алгоритмов пространственно-временной фузии, методов заполнения пропусков в данных ДЗЗ, архитектур глубокого обучения для восстановления изображений и обзоров современных подходов к анализу временных рядов растительности.

В научной среде распространены методы реконструкции на основе временных рядов, такие как гармонический анализ временных рядов (Harmonic Analysis of Time Series, HANTS) и фильтры Савицкого-Голея. Данные подходы демонстрируют ограниченную точность при работе с протяженными пропусками данных и часто ошибочно сглаживают кратковременные фенологические фазы, что критично для выявления стрессовых событий. Современные методы машинного обучения, включая алгоритмы случайного леса (Random Forest, RF) и градиентного бустинга (Gradient Boosting, GB), позволяют учитывать нелинейные зависимости, однако часто игнорируют пространственный контекст изображений, что снижает точность восстановления в зонах с неоднородной структурой растительного покрова.

Перспективным направлением стали подходы на основе глубокого обучения. Исследовательские прототипы на основе климатических данных и сетей радиально-базисных функций (Radial basis function networks, RBFN) обеспечивают реконструкцию NDVI для спутников Landsat, разрешение которых составляет 30 м, со средней абсолютной ошибкой $MAE = 0,05$. Методы реанализа характеризуются получением согласованных во времени и пространстве метеорологических данных за счет объединения наблюдений со спутника, наземных станций, радиозондов, и численных моделей прогноза погоды. Однако использование данных с разрешением около 27 км не позволяет учитывать локальные микроклиматические особенности конкретного поля, а пространственное разрешение 30 м недостаточно для задач точного земледелия. Методы пространственно-временной фузии демонстрируют точность, выраженную коэффициентом детерминации $R^2 = 0,87$ для NDVI, но требуют наличия безоблачных снимков высокого разрешения для обучения и не используют метеорологические параметры для физического восстановления значений под облаками. Комплексные системы на основе трансформерных сетей для слияния оптических данных радиолокатора с синтезированной апертурой (SAR) достигают $R^2 = 0,88$, однако требуют дорогостоящих радиолокационных

данных и сложной предобработки, что снижает их применимость в операционных системах агромониторинга.

Таким образом, выявлено **противоречие в практике**, которое состоит в том, что существующие промышленные системы, такие как EOS Crop Monitoring, и «Агросигнал», и научные методы, например, HANTS и RF, не обеспечивают требуемую точность реконструкции NDVI в условиях плотной облачности, так как либо не используют метеорологический контекст, либо оценивают точность на всем изображении, завышая метрики, либо работают с данными недостаточного пространственного разрешения.

Цель исследования состоит в повышении точности восстановления NDVI по мультиспектральным данным спутника Sentinel-2 в условиях облачности за счет разработки мультимодальной сверточной модели нейронной сети, основанной на методике раннего слияния спектрально-временных спутниковых данных и наземных метеорологических параметров, позволяющей обеспечить высокую точность восстановления вегетационного индекса в условиях облачного покрова при сохранении пространственной структуры растительности.

С использованием методов системного анализа обоснована гипотеза, или **центральная идея** исследования. Точность реконструкции NDVI под облаками может быть повышена за счет использования мультимодальной сверточной модели нейронной сети с ранним слиянием спектральных и метеорологических данных, что позволит перейти от временной интерполяции к физически обоснованной реконструкции значений NDVI непосредственно под облачным покровом.

Противоречие в науке состоит в отсутствии методов, обеспечивающих физически обоснованную реконструкцию индексов на данных высокого разрешения с объективной валидацией исключительно в зонах, закрытых облачным покровом, и учетом физиологических взаимосвязей растительности и погодных условий.

Общая научная задача состоит в разработке метода и алгоритмического обеспечения мультимодальной сверточной модели нейронной сети восстановления NDVI, интегрирующих спектрально-временной контекст вегетационных индексов, метеорологические параметры с ближайшей наземной станции и разработанные маски облаков с сохранением пространственной структуры растительного покрова.

Объектом исследования является процесс реконструкции вегетационных индексов по мультиспектральным спутниковым данным в условиях частичной и полной облачности.

Предметом исследования являются методы и алгоритмы модели мультимодальной сверточной нейронной сети для реконструкции NDVI, обеспечивающие раннее слияние спектрально-временных признаков и наземных метеопараметров, точную детекцию облаков и оценку качества исключительно на облачно-затронутых пикселях.

Декомпозиция общей научной задачи была проведена на три **частные научные задачи**:

1. Разработка метода и алгоритма детекции облаков для обработки информации из спутниковых изображений и формирования бинарных масок на основе трехкритериального анализа яркости, белизны и текстурной дисперсии, обеспечивающих минимизацию ложных срабатываний на светлых почвах.

2. Разработка модели мультимодальной сверточной нейронной сети с ранним слиянием спектральных и метеорологических признаков, приведенных в единое признаковое пространство, и специального алгоритмического обеспечения для оценки качества реконструкции, включающего метод оценки исключительно на облачно-затронутых пикселях.

3. Разработка программного комплекса для нейросетевой реконструкции вегетационных индексов, включающий методику экспериментального отбора оптимального подмножества метеорологических признаков, а также протокол маскированной оценки точности восстановления исключительно в зонах, закрытых облачным покровом.

Научная новизна диссертационного исследования состоит в получении следующих результатов:

1. Разработаны метод и алгоритм детекции облаков для формирования бинарных масок на основе трехкритериального анализа яркости, белизны и текстурной дисперсии, отличающиеся от известных тем, что применяют взвешенную логическую агрегацию RGB-каналов с адаптивным порогом, обеспечивающую минимизацию ложных срабатываний на светлых почвах при линейной вычислительной сложности.

2. Разработана модель мультимодальной сверточной нейронной сети с ранним слиянием спектральных и метеорологических признаков, приведенных в единое признаковое пространство, отличающаяся от известных тем, что интегрирует наземные метео данные на уровне скрытых представлений и использует функцию потерь, вычисляемую строго на облачных пикселях, что обеспечивает физически обоснованную реконструкцию индекса без артефактов интерполяции.

3. Разработан программный комплекс для нейросетевой реконструкции вегетационных индексов, отличающийся от известных тем, что включает методику статистического отбора метеопризнаков и протокол стратифицированной маскированной валидации, исключающие сезонное смещение данных и искусственное завышение метрик точности.

Практическая значимость результатов исследования определяется возможностью непосредственного внедрения разработанных методов, алгоритмов и программных модулей в системы оперативного агромониторинга и точного земледелия. Разработанный метод и алгоритм детекции облаков на основе трехкритериального анализа позволяет повысить достоверность предварительной обработки спутниковых данных и корректно выделять области, требующие восстановления, в сельскохозяйственных регионах с преобладанием оголенных почв. Разработанная модель мультимодальной сверточной нейронной сети с ранним слиянием спектральных и метеорологических признаков обеспечивает физически обоснованное восстановление значений вегетационных индексов под

облачным покровом при сохранении пространственной структуры растительного покрова. Разработанный программно-вычислительный комплекс для нейросетевой реконструкции вегетационных индексов реализует сквозной конвейер обработки данных от загрузки спутниковых снимков до генерации реконструированных карт. Результаты исследования могут быть использованы агрохолдингами ЮФО, например, ГК «Агрокомплекс», ГК «Юг Руси», для повышения достоверности спутникового мониторинга состояния посевов в условиях облачности, а также в научно-исследовательских центрах, таких как ФНЦ риса, ВНИИМК им. Пустовойта, для фенологического моделирования и оценки реакции сельскохозяйственных культур на метеорологические условия.

Методы исследования включают системный анализ, теория информации, пространственно-временная фильтрация, трёхмерная и двумерная свёрточная обработка, методика раннего слияния спектральных и метеорологических модальностей на уровне скрытых представлений, разработанная функция потерь MaskedMSE, вычисляемая исключительно по облачным пикселям, протокол стратифицированного разбиения выборки по календарным месяцам, корреляционный анализ Пирсона, расчёт фактора инфляции дисперсии VIF, анализ липшицевости операторов, блочно-диагональной структуры матрицы Якоби операции конкатенации, выпуклости целевой функции, метрики оценки точности R^2 , MAE, MSE, PSNR, SSIM. Моделирование и вычислительные эксперименты выполнены при помощи языка программирования Python 3.10, фреймворка глубокого обучения PyTorch 2.1.0 и аппаратного ускорения CUDA 12.1. Библиотеки обработки данных и визуализации включают GDAL, Rasterio, OpenCV 4.8.0, NumPy, Pandas, Matplotlib. Вычисления выполнены на процессоре Intel Core i7-12700K, 32 ГБ ОЗУ, видеоускоритель NVIDIA GeForce RTX 3060 12 ГБ.

Положения, выносимые на защиту:

1. Метод и алгоритм детекции облаков на основе трехкритериального анализа RGB-изображений Sentinel-2, отличающийся от известных спектральных тестов комплексным использованием адаптивного порога яркости, спектральной нейтральности и локальной текстурной дисперсии, обеспечивающий минимизацию ложных срабатываний на светлых почвах.
2. Модель мультимодальной свёрточной нейронной сети TemporalUNet с механизмом раннего слияния спектрально-временных и метеорологических признаков, приведенных в единое признаковое пространство, отличающаяся от известных архитектур сквозным распространением градиентов между модальностями через конкатенацию на уровне скрытых представлений и модифицированной функцией потерь, вычисляемой исключительно на облачно-затронутых пикселях, что обеспечивает физически обоснованную реконструкцию индекса без артефактов интерполяции при сохранении пространственного разрешения.
3. Программный комплекс нейросетевой реконструкции вегетационных индексов, включающий методику статистического отбора оптимального подмножества метеорологических признаков по критерию фактора инфляции

дисперсии и протокол стратифицированной маскированной валидации, демонстрирующий коэффициент детерминации $R^2 = 0,9595$, среднюю абсолютную ошибку $MAE = 0,0225$, пиковое отношение сигнал-шум $PSNR = 30,89$ дБ и индекс структурного сходства $SSIM = 0,8487$, что превышает показатели известных методов временной интерполяции и пространственно-временной фузии на 5-10 процентных пунктов по точности восстановления NDVI под облачным покровом

Достоверность и обоснованность результатов подтверждается применением апробированного научно-методического аппарата системного анализа, теории нейронных сетей и статистической обработки геопространственных данных. Корректность полученных выводов обеспечена использованием репрезентативного набора данных, включающего 85 дат спутниковой съемки Sentinel-2 L2A за полный вегетационный цикл подсолнечника с апреля по октябрь 2024 года на двух пространственно-независимых сельскохозяйственных полях общей площадью более 200 га. Достоверность результатов также подтверждается сходимостью экспериментальных данных с результатами, полученными при помощи известных методов реконструкции спутниковых снимков, а также положительными результатами апробации работы на ведущих научно-технических конференциях и публикацией материалов в рецензируемых изданиях. Требования продиктованы ГОСТ Р 70663-2023, ГОСТ Р 52438-2005, ГОСТ Р 57773-2017.

Соответствие паспорту научной специальности. Результаты исследования соответствуют паспорту научной специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика» по следующим пунктам:

4 – «Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта», а именно разработан трехкритериальный метод и соответствующий алгоритм детекции облачных объектов по полноцветным спутниковым снимкам, обеспечивающий формирование бинарных масок с минимизацией ложных срабатываний на светлых почвах за счет адаптивной пороговой обработки яркости, спектральной нейтральности и текстурной дисперсии.

12 – «Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации», а именно разработана мультимодальная сверточная модель нейронной сети с механизмом раннего слияния, реализующая приведение разнородных спектрально-временных и метеорологических признаков на уровне скрытых представлений, реализующая трансформацию разнородных данных в единое признаковое пространство и обеспечивающая объективный анализ точности реконструкции NDVI исключительно в облачно-затронутых областях при сохранении пространственного разрешения 10 м.

5 – «Разработка специального математического и алгоритмического обеспечения систем анализа, оптимизации, управления, принятия решений,

обработки информации и искусственного интеллекта», а именно разработан программный комплекс для нейросетевой реконструкции вегетационных индексов, включающий методику экспериментального отбора оптимального подмножества метеорологических признаков, а также протокол маскированной оценки точности восстановления исключительно в зонах, закрытых облачным покровом.

Апробация результатов исследования. Основные результаты диссертационного исследования доложены и обсуждены на ряде всероссийских и международных научно-технических конференций, среди которых:

1. Международная конференция «Trends in Electronics and Health Informatics (TEHI)», Самарканд, Узбекистан, 7-8 ноября 2025 г.
2. Международная конференция «Innovations in Sustainable Agricultural Systems, (ISAS)», Ставрополь, Россия, 5-6 марта 2025 г.;
3. Международная конференция «Current Problems in Applied Mathematics and Computer Systems, (CPAMCS)», Ставрополь, Россия, 27-31 октября 2025 г.

Публикации. По теме диссертационного исследования опубликовано 9 научных работ, из которых 4 статьи опубликованы в рецензируемых научных изданиях, рекомендованных ВАК при Министерстве науки и высшего образования Российской Федерации для опубликования основных научных результатов диссертаций на соискание ученой степени кандидата наук; 1 журнальная статья в рецензируемых научных изданиях, внесенных в библиографические и реферативные базы данных Scopus и Web of Science; 3 конференционные статьи, опубликованные в сборниках рецензируемых научных изданий, внесенных в библиографические и реферативные базы данных Scopus и Web of Science. Получено 2 свидетельства о государственной регистрации программ для ЭВМ.

Личный вклад соискателя. Все изложенные в диссертационной работе результаты получены при непосредственном участии автора. Автором самостоятельно проведен углубленный анализ отечественной и зарубежной научной литературы, определена цель и задачи исследования. Все основные этапы выполнены лично автором. Автором разработаны методы реконструкции вегетационных индексов с использованием мультимодальных данных и на их основе выработаны практические рекомендации. Все представленные результаты в рамках данного диссертационного исследования получены автором лично. В совместных опубликованных работах с другими авторами постановка и решение задач осуществлялись при непосредственном участии соискателя. В статье [5] соискателем проведен систематический обзор методов и алгоритмов интеллектуальной обработки сельскохозяйственных данных, применимых к культуре подсолнечника, выявлены ограничения существующих подходов к мониторингу вегетационных индексов в условиях облачности и недостаточной интеграции метеорологических данных, что послужило основанием для формулировки цели и задач диссертационного исследования. В статье [8]

соискателем проведен сравнительный анализ вегетационных индексов на изображениях различной модальности БПЛА и Sentinel-2, обоснованы преимущества мультимодальной интеграции для сельскохозяйственного мониторинга. В статье [7] соискателем разработана нейросетевая система преодоления облачных помех при прогнозировании вегетационных индексов по данным Sentinel-2 L2A с применением архитектуры раннего слияния признаков. В статье [6] соискателем обоснована методика слияния метеорологических данных и спутниковых изображений для прогнозирования вегетационных индексов, подтвердившая повышение точности при учете локального метеоконтекста. В статье [1] личным авторским вкладом соискателя является разработка метода и алгоритма детекции облаков для формирования бинарных масок на основе трехкритериального анализа RGB-изображений, обеспечивающего минимизацию ложных срабатываний на светлых почвах. В статье [2] соискателем разработана мультимодальная сверточная архитектура нейронной сети с ранним слиянием спектральных и метеорологических признаков, приведенных в единое признаковое пространство. В статьях [2, 4] соискателем проанализировано влияние различных наборов метеорологических признаков на точность реконструкции NDVI и обоснована оптимальная конфигурация из трех параметров. В статьях [1-5] автором опубликованы результаты программного моделирования реконструкции вегетационных индексов в условиях облачности с оценкой качества исключительно на облачно-затронутых пикселях, а также получены свидетельства о государственной регистрации программ для ЭВМ [9, 10].

Структура и объем диссертации. Диссертационная работа состоит из введения, четырех глав, заключения, списка литературы и двух приложений. Работа изложена на 211 страницах машинописного текста, содержит 25 рисунков и 13 таблиц. Список использованных источников литературы насчитывает 158 наименований. В диссертационной работе используется тройная нумерация формул, рисунков и таблиц, где первая и вторая цифры указывают на номер главы и раздела, а третья на порядковый номер рисунка, таблицы или формулы внутри раздела. Двойная нумерация формул принята вне разделов, где первая цифра обозначает номер главы, а вторая указывает на порядковый номер.

Основное содержание работы

Во введении приведено обоснование актуальности темы диссертационного исследования, а также сформулированы цель и научная задача, которая декомпозирована на ряд частных задач. Приведены объект и предмет исследования, представлена научная новизна, теоретическая и практическая значимость полученных результатов и приведены основные положения, выносимые на защиту.

В первой главе проведен комплексный системный анализ проблемы восстановления нормализованного разностного вегетационного индекса (NDVI) по данным дистанционного зондирования Земли в условиях частичной и

сплошной облачности. Установлено, что в регионах умеренного климата, включая основные сельскохозяйственные зоны Российской Федерации, частота облачного покрова в вегетационный период достигает 30-40%, что формирует систематические пропуски во временных рядах и снижает достоверность оперативного агромониторинга. Выполнен критический обзор промышленных платформ (EOS Crop Monitoring, «Агросигнал») и научных методов заполнения пропусков, таких как гармонический анализ временных рядов, фильтр Савицкого-Голея, алгоритмы случайного леса, методы пространственно-временной фузии, например, ESTARFM, и интеграции климатических данных.

Выявлены фундаментальные ограничения существующих подходов. Промышленные системы преимущественно используют временную интерполяцию или композитинг, что приводит к задержке актуальных данных на 5-10 дней и не учитывает физиологический контекст состояния растений. Научные методы параметрической аппроксимации демонстрируют критическое снижение точности при протяженных пропусках, сглаживают кратковременные фенологические фазы и игнорируют пространственный контекст. Подходы на основе глубокого обучения часто оценивают метрики по всему кадру, искусственно завышая показатели, либо используют данные реанализа с грубым пространственным разрешением 27 км, нивелирующим локальные микроклиматические особенности поля. Общая схема сбора данных для известных исследований приведена на рисунке 1.




Рисунок 1 – Обобщенная схема процесса получения спутниковых данных Sentinel-2 и возникновения пропусков в условиях облачности

На основании проведенного анализа сформулированы ключевые противоречия. В практике выявлено несоответствие между потребностью агробизнеса в непрерывных временных рядах высокого разрешения и возможностями существующих систем, не обеспечивающих реконструкцию под

плотным облачным покровом с учетом метеорологического контекста. В науке противоречие заключается в отсутствии методов, сочетающих высокое пространственное разрешение 10 м, точные локальные метеонаблюдения, учет пространственно-временных взаимосвязей и строгий протокол валидации исключительно на облачно-затронутых пикселях.

На основе цели, предмета и объекта исследования сформулирована математическая постановка общей научной задачи. Пусть $X_{spec} \in R^{B \times T \times C \times H \times W}$ – спектрально-временной тензор спутниковых данных за период мониторинга, где B – размер пакета, $T = 8$ – длина временного окна, C – количество спектральных каналов и вегетационных индексов, $H \times W$ – пространственное разрешение сцены. Пусть $X_{met} \in R^{B \times D}$ – вектор метеорологических параметров в момент времени t , прошедший z-стандартизацию по обучающей выборке, где D – количество метеопризнаков. Пусть $M \in \{0,1\}^{B \times 1 \times H \times W}$ – бинарная маска облачности, сформированная трехкритериальным детектором, где $M^{b,i,j} = 1$ указывает на облачный пиксель, а $M^{b,i,j} = 0$ – на ясный участок поверхности, b – индекс примера в пакете, i, j – пространственные координаты пикселя. Пусть $Y \in [0,1]^{B \times 1 \times H \times W}$ – истинное поле нормализованного разностного вегетационного индекса NDVI для целевой даты t .

Задача реконструкции NDVI формулируется как поиск оператора F_θ , который минимизирует ошибку восстановления строго на множестве облачных пикселей:

$$\hat{Y} = F_\theta(X_{spec}, X_{met}^{(S)}, M), \quad (1)$$

при условии $M^{b,i,j} = 1$, где $\hat{Y}$ – реконструированное поле индекса, θ – вектор обучаемых параметров архитектуры, $S \subseteq \{1, \dots, D\}$ – индексное множество выбранных метеопризнаков, формирующее вектор $X_{met}^{(S)}$. Для объективной оптимизации модели вводится модифицированная функция потерь MaskedMSE, вычисляемая исключительно на облачно-затронутых пикселях:

$$L(\theta) = \frac{1}{N_{cloud} + \varepsilon} \sum_{b=1}^B \sum_{i=1}^H \sum_{j=1}^W M^{b,i,j} (\hat{Y}^{b,i,j} - Y^{b,i,j})^2, \quad (2)$$

где $N_{cloud} = \sum_{b,i,j} M^{b,i,j}$ – количество облачных пикселей в пакете, $\varepsilon = 10^{-6}$ – константа для предотвращения деления на ноль. Общая задача состоит в поиске такого оператора реконструкции F_θ , который обеспечивает минимум целевой функции потерь L при соблюдении физических и вычислительных ограничений:

$$\begin{cases} L(F_\theta, M, S) \rightarrow \min, \\ 0 \leq \hat{Y}^{i,j} \leq 1, \\ |\hat{Y}_t^{i,j} - \hat{Y}_{t-1}^{i,j}| \leq \delta_{phen}, \\ T_{proc} \leq T_{max}, \end{cases} \quad (3)$$

где $\hat{Y}^{i,j} = F(X_{spec}, X_{met}^{(S)}, M)$ – реконструированное значение индекса для пикселя с координатами (i, j) , определяемое по формуле (1.4.1), $M \in \{0,1\}^{B \times 1 \times H \times W}$ – бинарная маска облачности, определяющая область вычисления ошибки, рассматриваемая в главе 2, $S \subseteq \{1, \dots, D\}$ – индексное множество выбранных метеорологических признаков, формирующее вектор $X_{met}^{(S)}$, рассматриваемый в главе 4, δ_{phen} – максимально допустимое изменение NDVI между соседними снимками с учетом фенологии культуры, T_{proc} – время обработки, T_{max} – максимальное допустимое время обработки.

Сформулированная общая научная задача рассматривается как задача на обеспечение требуемого значения показателя качества работы системы реконструкции NDVI в условиях облачности. Такое представление позволяет осуществить ее математическую постановку.

Дано: множество параметров системы $(X_{spec}, X_{met}^{(S)}, M, F, L)$ и степень облачности сцены $\beta_{cloud} \leq 0,95$.

Требуется: найти метод F_θ такой, что $F_\theta: X_{spec}, X_{met}^{(S)}, M \rightarrow \hat{Y}$ при ограничениях $R_{cloud}^2 \geq 0,95$, оцененное только на облачных пикселях, $MAE \leq 0,025$, $T_{proc} \leq 0,15$ с и пространственное разрешение должно быть не более 10 м. Требования продиктованы ГОСТ Р 70663-2023, ГОСТ Р 52438-2005, ГОСТ Р 57773-2017.

Общая задача декомпозирована на три частные научные задачи. Первая задача направлена на разработку метода детекции облаков, минимизирующего ложные срабатывания на светлых почвах. Вторая задача заключается в создании модели мультимодальной сверточной нейронной сети с ранним слиянием спектральных и метеорологических признаков. Третья задача предполагает разработку программного комплекса для повышения точности реконструкции вегетационных индексов в областях, закрытых облачностью. Декомпозиция общей научной задачи на частные представлена на рисунке 2.

Проведенный системный анализ создал методологический фундамент для перехода от математической интерполяции к физически обоснованной реконструкции на базе глубокого обучения.

Вторая глава диссертационного исследования посвящена разработке метода трехкритериального анализа спутниковых изображений и алгоритма детекции облаков для формирования бинарных масок на основе трехкритериального анализа полноцветных RGB-изображений Sentinel-2. Для разрешения противоречия между необходимостью высокой точности формирования бинарных масок и недостаточной эффективностью известных методов детекции облаков в условиях светлых подстилающих поверхностей разработан метод, обеспечивающий минимизацию ложных срабатываний на оголенных почвах без привлечения инфракрасных диапазонов и тяжелой морфологической постобработки.

Постановка задачи для разрабатываемого трехкритериального метода и алгоритма детекции облаков формулируется следующим образом.

Математическая модель данного этапа формализуется как построение оператора детекции Φ , генерирующего маску M :




Рисунок 2 – Схема декомпозиции общей научной задачи на частные научные задачи

$$\begin{cases} \Phi(X_{RGB}, SCL) = M, \\ M^{i,j} = (K_{bright} \wedge K_{white}) \vee (K_{bright} \wedge K_{tex}), \\ K_{bright} = \psi(Y_{norm}, T_{bright}), \\ K_{white} = \psi(W_{norm}, T_{white}), \\ K_{tex} = \psi(D, T_{tex}), \\ X_{specRGB} \in R^{H \times W \times 3}, \\ M \in \{0,1\}^{H \times W}, \end{cases} \quad (4)$$

где Φ – оператор детекции облаков, $X_{specRGB}$ – тензор входных спектральных RGB каналов, SCL – слой классификации сцены для адаптации порогов, M – итоговая бинарная маска облачности, $K_{bright}, K_{white}, K_{tex}$ – бинарные критерии яркости, белизны и текстурной дисперсии соответственно, ψ – оператор пороговой обработки, Y_{norm}, W_{norm}, D – метрики нормированной яркости, белизны и локальной дисперсии, $T_{bright}, T_{white}, T_{tex}$ – пороговые значения, $H \times W$ – пространственное разрешение снимка. Функция агрегации M , представляющая итоговую маску облачности, обеспечивает дифференциацию плотных кучевых облаков по критериям яркости и белизны, и перистых облаков по критериям яркости и текстуры, при отсечении светлых однородных объектов поверхности.

Математическая сущность метода заключается в построении функции классификации в многомерном пространстве признаков, где каждый пиксель описывается радиометрической яркостью, спектральной нейтральностью (белизной) и пространственной текстурной дисперсией. На рисунке 3 представлена схема разработанного трехкритериального детектора облаков.

Критерий нормированной яркости инвариантен к глобальным изменениям освещенности. Для каждого пикселя с координатами (i, j) вычисляется значение нормированной яркости $Y_{norm}(i, j)$ по формуле:

$$Y_{norm}(i, j) = \frac{R(i, j) + G(i, j) + B(i, j)}{3L_{max}}, \quad (5)$$

где R, G, B – коэффициенты спектральной яркости, в синем, зеленом и красном каналах соответственно, L_{max} – максимальное возможное значение яркости. Критерий яркости $K_{bright}(i, j)$ определяется за счет пороговой обработки нормированной яркости и представляет собой бинарную функцию принадлежности пикселя к классу высокоотражающих объектов:

$$K_{bright}(i, j) = \begin{cases} 1, & \text{если } Y_{norm}(i, j) \geq T_{bright}, \\ 0, & \text{иначе,} \end{cases} \quad (6)$$

где T_{bright} – адаптивный порог яркости. Пусть $\{y_1, y_2, \dots, y_n\}$ – упорядоченная по возрастанию выборка значений нормированной яркости Y_{norm} для всех ясных пикселей в сцене. Тогда пороговое значение яркости вычисляется как:

$$T_{bright} = y_k, \text{ где } k = [0,95 \cdot n], \quad (7)$$

где $[\cdot]$ – операция округления вверх до ближайшего целого числа.

Второй критерий основан на спектральных свойствах облаков и позволяет решить проблему дифференциации облаков от других ярких объектов. Для

количественной оценки белизны вводится метрика спектрального расстояния между каналами:

$$\Delta_{max}(i, j) = \max(|R - G|, |R - B|, |G - B|). \quad (8)$$

Нормированное значение белизны $W_{norm}(i, j)$ определяется как инверсия нормированной спектральной разности:

$$W_{norm}(i, j) = 1 - \frac{\Delta_{max}(i, j)}{L_{max}}. \quad (9)$$

Значение W_{norm} стремится к 1 для нейтрально-серых и белых объектов, таких как облака, бетонные сооружения, песчаные участки, и стремится к 0 для насыщенных цветов, например цвета густой растительности или глубокого водоема. Критерий белизны $K_{white}(i, j)$ формируется следующим образом:

$$K_{white}(i, j) = \begin{cases} 1, & \text{если } W_{norm}(i, j) \geq T_{white}, \\ 0, & \text{иначе,} \end{cases} \quad (10)$$

где $T_{white} = 0,85$ – пороговое значение белизны.

Третий критерий учитывает пространственную структуру объектов и позволяет отделить облака от других ярких и нейтральных объектов. Для учета этого признака используется оператор локальной дисперсии. Пусть $\Omega_{i,j}$ – окрестность пикселя (i, j) размером $w \times w$, в проведенном эксперименте $w = 5$. Локальная дисперсия яркости $D(i, j)$ вычисляется по формуле:

$$D(i, j) = \frac{1}{w^2} \sum_{(u,v) \in \Omega_{i,j}} (Y_{norm}(u, v) - \bar{Y}_{i,j})^2, \quad (11)$$

где $\bar{Y}_{i,j}$ – среднее значение яркости в окне $\Omega_{i,j}$:

$$\bar{Y}_{i,j} = \frac{1}{w^2} \sum_{(u,v) \in \Omega_{i,j}} Y_{norm}(u, v). \quad (12)$$

Критерий текстурной дисперсии $K_{tex}(i, j)$ определяется как:

$$K_{tex}(i, j) = \begin{cases} 1, & \text{если } D(i, j) \geq T_{tex}, \\ 0, & \text{иначе.} \end{cases} \quad (13)$$

где порог $T_{tex} = 0,0015$ установлен на основе анализа гистограмм дисперсии для облачных и ясных участков. Итоговое решение о принадлежности пикселя к классу «облако» принимается на основе взвешенной логической функции агрегации:

$$M(i, j) = (K_{bright} \wedge K_{white}) \vee (K_{bright} \wedge K_{tex}). \quad (14)$$

Данная формула означает, что пиксель классифицируется как облако, если он одновременно яркий и белый, что характерно для плотных кучевых облаков, ИЛИ если он яркий и имеет высокую текстурную дисперсию, что характерно для перистых облаков и краев облачных образований.

Такая логическая структура обеспечивает оптимальный баланс между ошибками первого рода, то есть ложное срабатывание на светлых почвах, и второго рода, а именно пропуск тонких перистых облаков. Критерий яркости выступает обязательным условием, в комбинации либо с белизной для плотных кучевых образований, либо с текстурной дисперсией для краев облачных полей и внутренних теней. Вынесение яркости в качестве общего множителя эффективно отсекает темные объекты с выраженной текстурой, снижая вероятность ложной детекции теней рельефа или водных объектов.

Алгоритмическая реализация метода сформирована в виде программного

модуля с линейной вычислительной сложностью $O(N)$ относительно количества пикселей. Для оптимизации вычисления текстурной дисперсии применен метод интегральных изображений, снижающий сложность операции с квадратичной до линейной. Исключение этапа морфологической фильтрации, компенсируемого оператором локальной дисперсии, сокращает задержку обработки стандартной сцены Sentinel-2 до 30 секунд на CPU. Для работы с данными произвольного размера реализован механизм блочной обработки с перекрытием 5 пикселей, обеспечивающий постоянное потребление памяти, корректное вычисление текстурных границ на стыках блоков и возможность распараллеливания на многоядерных процессорах.

Теоретический анализ подтвердил устойчивость метода к сенсорным шумам и атмосферным помехам. Усреднение по трем спектральным каналам снижает дисперсию случайного шума в $\sqrt{3}$ раз, а оператор локальной дисперсии в окне 5×5 обеспечивает естественную пространственную фильтрацию высокочастотных артефактов. Адаптивный порог яркости гарантирует устойчивость к вариациям угла съемки и дымке. Чувствительность метода к выбору фиксированных порогов белизны, составляющим 0,85, и текстуры, составляющим 0,0015, оптимизирована таким образом, чтобы минимизировать загрязнение обучающих выборок зашумленными данными, что критически важно для последующего обучения мультимодальной архитектуры реконструкции.

В третьей главе решается вторая частная научная задача диссертационного исследования, заключающаяся в разработке модели мультимодальной сверточной




Рисунок 3 – Схема метода реализации трехкритериального детектора облаков

нейронной сети с методикой раннего слияния спектрально-временных спутниковых данных и наземных метеорологических наблюдений, приведенных в единое признаковое пространство. В отличие от традиционных подходов с поздним слиянием или независимой обработкой модальностей, предложенная методика обеспечивает сквозное распространение градиентов между ветвями обработки, что позволяет модели учитывать физиологические взаимосвязи в системе «почва-растение-атмосфера» и компенсировать отсутствие оптических данных под сплошным облачным покровом.

Постановку задачи для математической модели реконструкции NDVI в условиях облачности можно представить как поиск обучаемого оператора F_θ , минимизирующего целевую функцию потерь при соблюдении ограничений общей задачи:

$$\begin{cases} \hat{Y}_t = F_\theta(X_{spec}, X_{met}^{(S)}, M), \\ L(\theta) = \frac{1}{N_{cloud}} \sum_{i,j} M^{i,j} (Y^{i,j} - \hat{Y}^{i,j})^2 \rightarrow \min_\theta, \\ 0 \leq \hat{Y}^{i,j} \leq 1, \\ |\hat{Y}_t^{i,j} - \hat{Y}_{t-1}^{i,j}| \leq \delta_{phen}, \\ T_{proc} \leq T_{max}, \end{cases} \quad (15)$$

где F – оператор реконструкции NDVI с обучаемыми весами θ , t – целевой момент времени, $X_{spec} \in R^{T \times C \times H \times W}$ – спектрально-временной тензор спутниковых данных, $X_{met}^{(S)}$ – оптимизированный вектор метеорологических параметров, $M \in \{0,1\}^{H \times W}$ – бинарная маска облачности, $L(\theta)$ – модифицированная функция потерь, вычисляемая исключительно на облачно-затронутых пикселях, N_{cloud} – общее количество облачных пикселей, Y и $\hat{Y}$ – истинное и реконструированное поля индекса, δ_{phen} – максимально допустимое изменение NDVI между соседними снимками с учетом фенологии, T_{proc} – время обработки, T_{max} – максимальное допустимое время обработки.

Центральным новшеством представленной методики является механизм трансляции низкоразмерного вектора метеопризнаков в высокоразмерный тензор пространственного признакового пространства. Проблема состоит в том, что сверточные слои архитектуры TemporalUNet ожидают на входе четырехмерные тензоры (B, C, H, W) , в то время как метеопризнаки доступны в виде одномерных векторов (B, D) . Прямая конкатенация невозможна из-за несовместимости размерностей, а традиционное решение через полносвязное отображение в выходной слой лишает модель возможности учитывать пространственную зависимость признаков. Предлагаемый оператор $\Psi: R^{B \times D} \rightarrow R^{B \times C_{met} \times H \times W}$ реализует операцию расширения за счет копирования вектора признаков на каждый пиксель изображения. Сначала вектор X_{met} пропускается через полносвязный слой с весами $W_{proj} \in R^{C_{met} \times D}$ и функцией активации ReLU для приведения глубины канала к значениям C_{met} , совпадающим с глубиной признаков временного блока.

Результатом этой операции является тензор $F_{met}^{proj} \in R^{B \times C_{met}}$. Далее выполняется операция пространственного повторения:

$$\tilde{F}_{met}(b, c, h, w) = F_{met}^{proj}(b, c), \quad (16)$$

где $h \in [1, H]$ и $w \in [1, W]$. Таким образом, один и тот же метеорологический паттерн воспроизводится для всех $H \times W$ пикселей в пределах одного пакета обучающих данных. Окончательный объединенный тензор формируется посредством операции конкатенации вдоль оси каналов:

$$F_{fused} = Concat(F_{temp}, \tilde{F}_{met}, M). \quad (17)$$

Итоговый тензор имеет размерность $R^{B \times C_{total} \times H \times W}$, где $C_{total} = C_{temporal} + C_{met} + 1 = 64 + 64 + 1 = 129$. Такая структура позволяет сверточным фильтрам декодера получать информацию о текущем состоянии растительности из временного блока, внешних погодных условиях из метео-блока и локальных условиях видимости из маски одновременно в каждом слое обработки. На рисунке 5 представлена структурная схема разработанной модели мультимодальной сверточной нейронной сети TemporalUNet.

Разработанная гибридная архитектура TemporalUNet состоит из трех функциональных блоков. Временной блок на базе двух слоев трехмерной свертки извлекает пространственно-временные признаки эволюции растительного покрова из последовательности из 8 дней по 7 спектральным индексам. Выходной срез по временной оси формирует тензор глубины 64. Метеорологический блок проецирует стандартизированный вектор наблюдений в тензор $\tilde{F}_{met} \in \mathbb{R}^{B \times 64 \times H \times W}$. Операция конкатенации формирует единое признаковое пространство глубиной 129 каналов, которое передается в двумерный декодер из трех Conv2D-слоев с сигмоидной активацией на выходе, гарантирующей физически допустимый диапазон значений NDVI $[0, 1]$.

Для объективной оптимизации весовых коэффициентов исключен вклад ясных пикселей, где модель тривиально воспроизводит входные данные. Разработана модифицированная функция потерь MaskedMSE, вычисляемая исключительно на множестве облачно-затронутых пикселей:

$$L = \frac{\sum_{b=1}^B \sum_{i=1}^H \sum_{j=1}^W M^{b,i,j} (\hat{Y}^{b,i,j} - Y^{b,i,j})^2}{\sum_{b=1}^B \sum_{i=1}^H \sum_{j=1}^W M^{b,i,j} + \varepsilon}, \quad (18)$$

где $M^{b,i,j} \in \{0,1\}$ – бинарная маска облачности, $\varepsilon = 10^{-6}$ – константа для предотвращения деления на ноль. Функционирование модели формализовано системой уравнений, описывающей последовательное преобразование тензоров от входных модальностей до генерации реконструированного поля $\hat{Y}$:

$$\begin{cases}
F_1 = \text{ReLU}(\text{Conv3D}(X_{\text{spec}}, W_1, b_1)), \\
F_2 = \text{ReLU}(\text{Conv3D}(F_1, W_2, b_2)), \\
F_{\text{temp}}^{b,f,i,j} = F_2^{b,f,T,i,j}, \\
F_{\text{met}}^{\text{proj}} = \text{ReLU}(W_m \cdot X_{\text{met}}^S + b_m), \\
\tilde{F}_{\text{met}}^{b,f,i,j} = F_{\text{met}}^{\text{proj},b,f}, \\
F_{\text{fused}} = \text{Concat}(F_{\text{temp}}, \tilde{F}_{\text{met}}, M), \\
D_1 = \text{ReLU}(\text{Conv2D}(Z, W_{d1}, b_{d1})), \\
D_2 = \text{ReLU}(\text{Conv2D}(D_1, W_{d2}, b_{d2})), \\
\hat{Y} = \sigma(\text{Conv2D}(D_2, W_{\text{out}}, b_{\text{out}})), \\
L = \frac{\sum M \odot (\hat{Y} - Y)^2}{\sum M + \varepsilon},
\end{cases} \quad (19)$$

где Conv3D и Conv2D – операции трехмерной и двумерной свертки соответственно, Concat – операция конкатенации по оси каналов, $\odot$ – произведение Адамара, σ – сигмоидная функция активации, $\hat{Y}$ – реконструированное поле NDVI, L – модифицированная функция потерь, вычисляемая исключительно на пикселях, классифицированных как облачные, $\varepsilon = 10^{-6}$ – малая константа для предотвращения деления на ноль.




Рисунок 5 – Структурная схема модели мультимодальной сверточной нейронной сети TemporalUNet

Теоретический анализ подтвердил математическую обоснованность и устойчивость архитектуры. Доказана 1-липшицева устойчивость метеоблока к инструментальным шумам станций, возмущение δ_{phen} на выходе линейной проекции ограничено произведением спектральной нормы матрицы весов и уровня шума. Операция пространственного расширения не вносит дополнительной дисперсии. Анализ матрицы Якоби операции конкатенации показал ее блочно-диагональную единичную структуру, что гарантирует

аддитивное расщепление градиентов без эффекта затухания или взрыва. Ландшафт функции потерь в окрестности оптимума является выпуклым по предсказанию на области $[0, 1]$, а отсутствие нелинейностей после финального сверточного слоя исключает формирование ложных локальных минимумов.

Алгоритмическая реализация отличается высокой вычислительной эффективностью. Общее количество обучаемых параметров модели составляет 154 500, что относит ее к классу легких архитектур. Вычислительная сложность оценивается как линейная $O(N)$ относительно количества пикселей сцены. Для обоснования применимости разработанной архитектуры в оперативных системах агромониторинга проведена оценка вычислительной сложности и количества параметров модели, представленная в таблице 1.

Таблица 1 – Распределение параметров по блокам модели TemporalUNet

Блок	Параметры
Временной блок (Conv3D $\times 2$)	$32 \times 7 \times 33 + 32 + 64 \times 32 \times 33 + 64 = 61440$
Линейный метеорологический блок	При минимальном $D = 3$: $64 \times 3 + 64 = 256$
Декодер (Conv2D $\times 3$)	$64 \times 129 \times 32 + 64 + 32 \times 64 \times 32 + 32 + 1 \times 32 \times 12 + 1 = 92865$
Итого	154500 параметров

Время прямого прохода, или инференса, для стандартной сцены Sentinel-2 размером 146×217 пикселей составляет 0,15 с на GPU, а обучение на 2000 стратифицированных примерах занимает 2 часа на 100 эпох, что полностью соответствует требованиям оперативных систем агромониторинга.

В четвертой главе разработана методика выбора оптимального подмножества метеорологических признаков S_{opt} для реконструкции нормализованного разностного вегетационного индекса в условиях облачности, а также создано полное алгоритмическое и программное обеспечение системы нейросетевой обработки спутниковых и метеорологических данных. Постановку задачи для математической модели отбора оптимального подмножества метеорологических признаков представима как поиск конфигурации признаков $S \subseteq F$, максимизирующей точность восстановления строго на облачно-затронутых пикселях при статистических ограничениях:

$$\begin{cases} S_{opt} = \arg \max_{S \subseteq F} R_{cloud}^2(S) \\ VIF(f_k) \leq 5, \forall f_k \in S, \\ |R_{train}^2(S) - R_{val}^2(S)| \leq \Delta_{crit} \\ 3 \leq |S| \leq 8, \end{cases}, \quad (20)$$

где $F = \{f_1, f_2, \dots, f_D\}$ – полный набор доступных метеорологических признаков, прошедших z-стандартизацию по обучающей выборке, $R_{cloud}^2(S)$ – коэффициент детерминации, вычисляемый исключительно по множеству облачных пикселей

$\Omega_c = \{(i, j) | M_{\{i, j\}} = 1\}$, $VIF(f_k)$ – фактор инфляции дисперсии k -го признака, Δ_{crit} – эмпирически установленный допустимый разрыв между обучающей и валидационной выборками.

Решение задачи реализовано через эмпирико-аналитический подход, включающий последовательное обучение модели на заранее сформированных логических конфигурациях, их сравнение по маскированным метрикам качества и статистическую диагностику с использованием коэффициента корреляции Пирсона и фактора инфляции дисперсии.

Экспериментальная база исследования сформирована из 85 снимков Sentinel-2 Level-2A за полный вегетационный цикл подсолнечника с апреля по октябрь 2024 г. на двух сельскохозяйственных полях общей площадью более 200 га в Краснодарском крае. Для обеспечения физической согласованности спутниковых и наземных наблюдений разработан строгий протокол временной синхронизации: метеорологические данные с автоматизированной станции г. Армавир на расстоянии 25-29 км от полей агрегируются за 24 часа, предшествующие моменту прохода спутника, с последующей z-стандартизацией по обучающей выборке для предотвращения утечки данных:

$$X_{met} = \frac{1}{N} \sum_{k=1}^N z_{t-k \cdot \Delta_t}, \quad (21)$$

где $z_{t-k \cdot \Delta_t}$ – вектор наблюдений в k -й часовой интервал до момента съемки, $N = 24$ – число часов в сутках. Для исключения сезонного смещения и предотвращения утечки временных данных при оценке обобщающей способности модели применен алгоритм стратифицированного разбиения выборки по календарным месяцам в пропорции 80/20. Пусть $D_m \subset D$ – подмножество семплов месяца m , содержащее N_m элементов. Для каждого месяца генерируется случайная перестановка индексов σ_m . Обучающее множество D_{train} формируется за счет выбора первых $\lfloor \alpha \cdot N_m \rfloor$ элементов из каждой страты, где $\alpha = 0,8$:

$$D_{train} = \cup_m \{s_{m, \sigma_m(j)} | 1 \leq j \leq \lfloor \alpha \cdot N_m \rfloor\}. \quad (22)$$

Валидационное множество D_{val} образуется из оставшихся элементов:

$$D_{val} = \cup_m \{s_{m, \sigma_m(j)} | \lfloor \alpha \cdot N_m \rfloor + 1 \leq j \leq N_m\}. \quad (23)$$

Данная процедура гарантирует присутствие всех фенологических фаз как в обучающей, так и в валидационной выборках, что исключает риск переобучения модели на узком временном интервале и обеспечивает репрезентативность оценки метрик $R_{\Omega_c}^2$, MSE, PSNR и SSIM. В результате сформировано $N_{train} = 2278$ обучающих и $N_{val} = 569$ валидационных примеров, независимых по временной метке и пространственному расположению полей. Пример использованных в эксперименте изображений представлен на рисунке 6.

Создан модульный программный комплекс на языке Python с использованием фреймворка PyTorch, реализующий сквозной конвейер обработки от загрузки GeoTIFF-файлов до генерации реконструированных карт вегетационных индексов. Архитектура комплекса включает шесть

функциональных модулей, а именно модуль синхронизации, нормализации и масштабирования данных, модель стратифицированного разбиения данных, модуль трехкритериальной детекции, модуль формирования тензорных последовательностей, модуль обучения разработанной модели и модуль инференса и декодирования. Схема программного комплекса нейросетевой реконструкции представлена на рисунке 7.

Проведен эмпирический поиск оптимального подмножества метеорологических признаков. Протестировано пять экспериментальных наборов, или сетов, различающихся количеством и типом включенных параметров. Минимальный набор признаков включает в себя относительную влажность, среднюю температуру и атмосферное давление. Максимальный набор включает в себя такие параметры, как относительная влажность, средняя температура, максимальная температура, минимальная температура, атмосферное давление, температура точки росы, суточная амплитуда температуры, давление на станции. Статистический анализ на основе корреляции Пирсона и фактора инфляции дисперсии VIF подтвердил отсутствие критической мультиколлинеарности в оптимальной конфигурации:

$$r_{X_j, Y} = \frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (24)$$

где $r_{X_j, Y}$ – коэффициент корреляции между j -м метеопризнаком и целевой переменной Y , x_{ij} – значение j -го признака в i -м наблюдении, y_i – истинное значение индекса в i -м наблюдении, $\bar{x}_j$, $\bar{y}$ – выборочные средние, n – объем выборки. Значение $|r| > 0,5$ интерпретируется как умеренная или сильная линейная связь, что является порогом для включения признака в предварительный отбор.




Рисунок 6 – Пример данных из обучающего набора: а) оригинальное RGB изображение; б) NDVI; в) EVI; г) SAVI; д) Barren Soil; е) Moisture Index; ж) Moisture Stress; з) Agriculture




Рисунок 7 – Схема программного комплекса нейросетевой реконструкции вегетационных индексов

Второй этап включает диагностику мультиколлинеарности посредством фактора инфляции дисперсии VIF. Для каждого признака X_j вычисляется:

$$VIF_j = \frac{1}{1-R_j^2}, \quad (25)$$

где R_j^2 – коэффициент детерминации регрессии признака X_j на все остальные признаки множества $S \setminus X_j$:

$$X_j = \beta_0 + \sum_{k \neq j} \beta_k X_k + \varepsilon. \quad (26)$$

Значение $VIF_j > 5$ указывает на критическую мультиколлинеарность, требующую исключения признака из набора. Результаты расчетов представлены в таблице 2.

Таблица 2 – Статистический анализ информативности метеорологических признаков

Признак	Описание	Корреляция с NDVI, $r_{X_j,Y}$	VIF	Статус в эксперименте
U	Относительная влажность, %	0,72	2,1	Включен
T	Средняя температура, °C	0,68	2,8	Включен

P	Атмосферное давление, гПа	0,54	1,5	Включен
T_d	Точка росы, °C	0,71	4,7	Коллинеарность
T_x	Макс. температура, °C	0,65	3,9	Избыточен с T
T_n	Мин. температура, °C	0,63	3,5	Избыточен с T
P_o	Давление на уровне станции	0,52	2,3	Дублирует P

Результаты показывают, что расширенный набор Set 4 из 7 метеопризнаков обеспечивает наилучший баланс точности и устойчивости. Результаты сравнения различных наборов метеопризнаков по метрикам качества реконструкции NDVI представлены в таблице 3.

Таблица 3 – Значения метрик, полученные в ходе эксперимента

Название набора	Признаки	R^2	MSE	PSNR, дБ	SSIM
Set 1	U, T, P	0,9555	0,00088	30,57	0,8323
Set 2	U, T, T_x, T_n	0,9557	0,00091	30,42	0,8457
Set 3	U, T, P, T_d	0,9579	0,00082	30,87	0,8547
Set 4	$U, T, T_x, T_n, P, T_d, T_{range}$	0,9595	0,00081	30,89	0,8487
Set Full	$U, T, T_x, T_n, P, P_o, T_d, T_{range}$	0,9579	0,00085	30,69	0,8449

Качественная оценка на рисунке 8 демонстрирует результаты восстановления при экстремально высокой облачности в 94,5% для всех моделей. В отдельных примерах с критическим уровнем облачности более 90% модель с полным набором признаков Set Full может демонстрировать визуально приемлемые результаты за счет избыточной параметризации. Однако при систематической оценке на всей валидационной выборке именно набор Set 1 обеспечивает наилучший баланс между точностью реконструкции и устойчивостью к переобучению.

Выполнена комплексная сравнительная оценка с наиболее релевантными существующими подходами: промышленным процессором Sen2Cor, методами временной интерполяции, такими как HANTS, SG-фильтр, алгоритмом машинного обучения Random Forest, подходом пространственно-временной фузии ESTARFM и методом интеграции климатических данных CGF. Ключевой методологической особенностью исследования является строгий протокол валидации, все метрики вычисляются исключительно на множестве пикселей, классифицированных как облачно-затронутые, что устраняет фундаментальное ограничение большинства аналогов (таблица 4).

Анализ данных таблицы позволяет сформулировать следующие выводы о конкурентоспособности разработанной системы. Во-первых, в аспекте точности реконструкции непосредственно под облачным покровом предложенная модель демонстрирует значение коэффициента детерминации $R^2 = 0,9595$, что превышает показатели методов временной гармонической интерполяции на 5-10 процентных пунктов в условиях протяженных облачных пропусков. Во-вторых,

пространственная детализация восстановленных полей на уровне 10 м сохраняет внутрипольную неоднородность и границы агротехнических контуров, которые полностью сглаживаются в методах фьюзии на базе данных с разрешением 1 км. В-третьих, качество метеорологического контекста обеспечивает физическую обоснованность восстановления, в отличие от метода CGF, опирающегося на глобальный реанализ ERA-5 с разрешением 27 км, разработанная модель интегрирует измерения наземной автоматизированной метеостанции, расположенной в пределах 25-29 км от полей.




Рисунок 8 – Результат восстановления NDVI под высоким облачным покровом 94,5%: а) исходные изображения True Color; маски облаков; реальный NDVI; б) восстановленный NDVI и ошибка для Set 1; в) восстановленный NDVI и ошибка для Set 2; г) восстановленный NDVI и ошибка для Set 3; д) восстановленный NDVI и ошибка для Set 4; е) восстановленный NDVI и ошибка для Set Full

Сформулированы технические и методологические положения для интеграции системы в операционные контуры агропредприятий. Определены требования к вычислительной инфраструктуре, а именно GPU уровня NVIDIA RTX 3060, 16 ГБ ОЗУ, протоколы блочной обработки крупных территорий с

перекрытием 5 пикселей для устранения артефактов стыковки, алгоритмы тонкой настройки под новые культуры и регионы, а также механизмы отказоустойчивости при пропусках метеоданных. Подтверждена готовность программного комплекса к пилотной эксплуатации, зафиксированная двумя свидетельствами о государственной регистрации программ для ЭВМ.

Таблица 4 – Сравнительный анализ методов реконструкции NDVI

Метрика / Характеристика	Sen2Cor / Пром. платформы	HANTS / SG-фильтр	Random Forest	ESTARF M	CGF	Разработанная модель
Источник данных	Sentinel-2 L2A	Зависит от источника	MODIS	Landsat, MODIS	Landsat, ERA-5	Sentinel-2 L2A
Пространственное разрешение	10 м	Зависит от данных	1 км	30 м	30 м	10 м
Метеоданные	Нет	Нет	Реанализ (грубо)	Нет	ERA-5 27 км	Наземная станция
R ² (общий)	N/A (маскирование)	0,85	0,974	0,87	0,90	0,9763
R ² (только под облаками)	0 (нет реконструкции)	0,50	Не оценено	0,50	0,88	0,9595
MAE	N/A	0,042	0,024	0,023	0,05	0,0225
RMSE	N/A	—	0,034	0,023	—	0,0285
PSNR, дБ	—	—	—	—	—	30,89
SSIM	—	—	—	—	—	0,8487
Протокол валидации	Визуальный / все изображение	Все изображение	Все изображение	Все изображение	Симулированные пропуски	Только облачные пиксели
Учет пространственного контекста	Нет	Нет	Нет (пиксельный)	Частично	Нет	Да (Conv3D+ Conv2D)
Стратегия слияния модальностей	Нет	Нет	Позднее / нет	Нет	Последовательное	Раннее, на уровне признаков

Основные результаты и выводы по работе

В рамках диссертационного исследования решена актуальная научная задача повышения точности реконструкции нормализованного разностного вегетационного индекса NDVI по данным Sentinel-2 в условиях облачности. Достигнута цель исследования, заключающаяся в разработке мультимодального метода глубокого обучения, интегрирующего спектрально-временной контекст спутниковых изображений, наземные метеорологические наблюдения и авторские алгоритмы детекции облаков.

На основании выполненных исследований сформулированы следующие основные результаты и выводы:

1. Разработан метод и алгоритм детекции облаков для обработки информации из спутниковых изображений и формирования бинарных масок на основе трехкритериального анализа яркости, белизны и текстурной дисперсии. Предложенный подход минимизирует ложные срабатывания на светлых почвах за счет учета пространственных текстурных характеристик, что позволяет исключить загрязнение обучающих выборок невалидными данными и повышает качество последующего восстановления вегетационных индексов.

2. Разработана модель мультимодальной сверточной нейронной сети TemporalUNet с методикой раннего слияния спектральных и метеорологических признаков, приведенных в единое признаковое пространство. Модель обеспечивает сквозное распространение градиентов между модальностями, что позволяет учитывать физиологические связи в системе «почва-растение-атмосфера». Использование модифицированной функции потерь MaskedMSE, вычисляемой исключительно на облачно-затронутых пикселях, позволило сфокусировать обучение на задаче восстановления пропусков, а не на копировании ясных участков, и достичь коэффициента детерминации $R^2 = 0,9595$ при средней абсолютной ошибке $MAE = 0,0225$ на тестовом множестве облачных пикселей.

3. Разработан программный комплекс для нейросетевой реконструкции вегетационных индексов, включающий методику экспериментального отбора оптимального подмножества метеорологических признаков. Эмпирическая валидация пяти конфигураций подтвердила оптимальность расширенного набора метеопризнаков из 7 параметров, включающих относительную влажность, среднюю, максимальную, минимальную температуру и ее амплитуду, атмосферное давление и точку росы. Комплекс реализует строгий протокол валидации, исключая методологическую предвзятость, и защищен двумя свидетельствами о государственной регистрации программ для ЭВМ.

Таким образом, гипотеза о том, что переход от математической интерполяции к физически обоснованной реконструкции на базе мультимодальной модели с ранним слиянием позволяет обеспечить непрерывный мониторинг состояния посевов в условиях плотной облачности, подтверждена экспериментально. Разработанные методы и алгоритмическое обеспечение создают методологическую основу для внедрения в операционные системы агрохолдингов и научно-

исследовательских центров для повышения надежности спутникового мониторинга.

Основные публикации по теме диссертации

Статьи в рецензируемых научных изданиях, рекомендованных ВАК при Министерстве науки и высшего образования РФ

1. **Арустамян, В. А.** Влияние влажностно-барических параметров на качество спектрального восстановления NDVI на спутниковых изображениях сельскохозяйственных полей / В. А. Арустамян // Системы анализа и обработки данных. – Принято в печать. – 1,07 п.л./ авт.вклад 1,07 п.л. **(БС 4)**.
2. **Арустамян, В. А.** Глубокая модель предсказания вегетационных индексов на основе совмещения спутниковых и метеорологических данных / В. А. Арустамян // Системы анализа и обработки данных. – Принято в печать. – 0,93 п.л./ авт.вклад 0,93 п.л. **(БС 4)**.
3. **Арустамян, В. А.** Мультимодальная сверточная нейронная сеть для восстановления NDVI под облачным покровом с использованием температурного контекста / В. А. Арустамян // Известия Юго-Западного государственного университета. – Принято в печать. – 1,07 п.л./ авт.вклад 1,07 п.л. **(БС 3)**.
4. **Арустамян, В. А.** Реконструкция вегетационных индексов на основе данных Sentinel-2 в условиях облачности с помощью мультимасштабной сверточной архитектуры / В. А. Арустамян // Известия Юго-Западного государственного университета. – Принято в печать. – 1,07 п.л./ авт.вклад 1,07 п.л. **(БС 3)**.

Статьи в рецензируемых научных журналах, внесенных в библиографические и реферативные базы данных Scopus и Web of Science

5. **Arustamyan, V.** A systematic review of methods and algorithms for the intelligent processing of agricultural data applied to sunflower crops / V. Arustamyan, P. Lyakhov, U. Lyakhova, R. Abdulkadirov // Machine Learning and Knowledge Extraction. – 2025. – Vol. 7. – Art. 130. – DOI: 10.3390/make7040130. – 2,60 п.л./ авт.вклад 0,65 п.л. **(Q1 Scopus)**.

В прочих рецензируемых изданиях, индексируемых Web of Science и Scopus

6. **Arustamyan, V.** Fusion of Meteorological Data and Satellite Imagery for Vegetation Index Prediction Using Deep Learning / V. Arustamyan, P. Lyakhov // Current Problems In Applied Mathematics and Computer Systems : proceedings of the International Conference CPAMCS 2025. – Cham : Springer, 2026. – Accepted paper. – 2,13 п.л./ авт.вклад 1,07 п.л.

7. **Arustamyan, V.** Neural Network Based System for Overcoming Cloud Obstruction in Vegetation Index Forecasting Using Sentinel-2 L2A Satellite Data / V. Arustamyan, P. Lyakhov, R. Abdulkadirov // Trends in Electronics and Health Informatics : proceedings of the 5th International Conference TEHI 2025. – Cham : Springer, 2026. – Accepted paper. – 2,60 п.л./ авт.вклад 0,87 п.л.
8. Lyakhov, P. Comparative Analysis of Vegetation Indices on Agricultural Images of Different Modalities / P. Lyakhov, A. Orazhev, **V. Baboshina**, S. Odintsov, A. Esaulko // Innovations in Sustainable Agricultural Systems, Agriculture 4.0 and Precision Agriculture, Volume 2 : proceedings of the International Conference ISAS 2025 / ed. by I. Samoylenko, T. Rajabov. – Cham : Springer, 2025. – DOI: 10.1007/978-3-031-98127-2_5. – 0,73 п.л./ авт.вклад 0,15 п.л.

Свидетельства о государственной регистрации программ для ЭВМ

6. Свидетельство о государственной регистрации программы для ЭВМ № 2026617747. Система заполнения пропусков в спутниковых данных, вызванных облачностью, на основе анализа временных рядов и метеорологического контекста / Арустамян В. А., Ляхов П. А.; правообладатель ФГАОУ ВО «Северо-Кавказский федеральный университет». – Заявка № 2026616700; заявл. 16.03.2026; зарег. 20.03.2026.
7. Свидетельство о государственной регистрации программы для ЭВМ № 2026661412. Система прогнозирования растительных индексов на основе спутниковых и метеорологических данных / Арустамян В. А., Ляхов П. А.; правообладатель ФГАОУ ВО «Северо-Кавказский федеральный университет». – Заявка № 2026616737; заявл. 16.03.2026; зарег. 21.04.2026.