

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра информатики и программирования

**РАЗРАБОТКА ПРИЛОЖЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ТИПОВ
ЗЕМЛЕПОЛЬЗОВАНИЯ ПО СПЕКТРАЛЬНЫМ КАНАЛАМ
СПУТНИКОВЫХ СНИМКОВ SENTINEL-2 С ИСПОЛЬЗОВАНИЕМ
МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ**

студента 2 курса 273 группы

направления 02.03.04 Математическое обеспечение и администрирование
информационных систем

факультета компьютерных наук и информационных технологий

Абросимова Андрея Михайловича

Научный руководитель

к. ф.-м. н., доцент

подпись, дата

М. В. Огнева

Зав. кафедрой

к. ф.-м. н., доцент

подпись, дата

М. В. Огнева

Саратов 2026

ВВЕДЕНИЕ

Стремительное развитие методов машинного обучения и их применение для дистанционного зондирования Земли предоставляет новые возможности для решения прикладных задач в области экологического мониторинга, сельского хозяйства и градостроительства. Увеличение доступности вычислительных ресурсов и совершенствование алгоритмов работы с пространственными данными делают анализ земной поверхности по спутниковым снимкам перспективным и востребованным направлением.

Спутниковые снимки Sentinel-2 предоставляют бесплатный доступ к 12 спектральным каналам, однако большинство существующих методов классификации землепользования используют лишь видимые и ближний инфракрасный каналы, игнорируя каналы «красного края» (Red Edge) и коротковолнового инфракрасного диапазона (SWIR), которые несут критическую информацию о состоянии растительности и влажности почвы. Кроме того, распространённые подходы, основанные на классификации изолированных пикселей, не учитывают пространственный контекст, что приводит к ошибкам на границах объектов и при спектральной схожести разных классов. Таким образом, разработка подхода, использующего полный спектральный сигнал Sentinel-2 и учитывающего пространственный контекст является более чем актуальной.

Задача классификации землепользования и земного покрова возникла на стыке дистанционного зондирования, геоинформатики и машинного обучения. Наиболее часто в исследованиях рассматриваются следующие основные категории: водные объекты, лесные массивы, сельскохозяйственные угодья и урбанизированные территории. Идентификация этих типов по спутниковым снимкам позволяет перейти от визуального дешифрирования к автоматизированному количественному анализу.

Целью выпускной квалификационной работы является разработка

программного приложения для классификации типов землепользования по спектральным каналам спутниковых снимков Sentinel-2 с использованием методов машинного обучения.

Для достижения поставленной цели были сформулированы следующие задачи:

1. Провести обзор существующих методов классификации на основе спутниковых данных и машинного обучения.

2. Изучить спектральные характеристики каналов Sentinel-2 и информативность основных спектральных индексов.

3. Выполнить предобработку и разведочный анализ исходного датасета, а также провести ручную разметку снимков Sentinel-2 с полным 12-канальным набором.

4. Разработать ансамблевую модель классификации по патчам 64×64 пикселя и модель сегментации на основе архитектуры U-Net с энкодером EfficientNet-B0.

5. Провести оценку точности обеих моделей на отложенной тестовой выборке по метрикам Accuracy, F1-score и IoU.

6. Реализовать десктоп-приложение с графическим интерфейсом, обеспечивающее загрузку снимков Sentinel-2, классификацию, сегментацию и RGB-визуализацию.

Методологические основы автоматической классификации типов территорий по данным дистанционного зондирования с применением методов глубокого обучения представлены в работах С. Минаи (S. Minaee), О. Роннебергера (O. Ronneberger), Л.-С. Чена (L.-S. Chen), К. Хэ (K. He), К. Симоняна (K. Simonyan) и А. Циссермана (A. Zisserman), А. Крижевского (A. Krizhevsky), А. А. Адегуна (A. A. Adegun), Д. Фири (D. Phiri), С. Таганаки (S. Taghanaki). Прикладные аспекты сегментации территорий и анализа спутниковых данных в отечественной практике отражены в работах О. О. Каюмова, В. К. Вика, В. В. Чурсина, Р. К. Фёдорова.

Практическая значимость магистерской работы заключается в

создании готового программного инструмента — десктоп-приложения с тремя режимами: классификация патчей, сегментация и RGB-визуализация. Приложение собрано в автономный EXE-файл (PyInstaller, 2,8 ГБ), не требующий установки Python и доступа к интернету. Разработанное приложение предназначено для автоматической классификации и сегментации типов землепользования по одному снимку Sentinel-2 L2A. . Работа выполнена в сотрудничестве с географическим факультетом СГУ, специалисты которого выступили предметными экспертами на всех этапах и предоставили исходные данные векторной разметки.

Структура и объём работы. Магистерская работа состоит из введения, восьми разделов, заключения, списка использованных источников и шести приложений. Общий объём работы — 127 страниц, из них 59 страниц — основное содержание, включая 29 рисунков и 7 таблиц. Список использованных источников информации — 29 наименований.

КРАТКОЕСОДЕРЖАНИЕ РАБОТЫ

В первом разделе "Характеристика спутниковых снимков" проведен анализ существующих программных решений (ArcGIS, QGIS, SNAP, Google Earth Engine, ENVI), их лицензий, поддержки 12 каналов, наличия глубокого обучения, автономности и удобства интерфейса. Сделан вывод, что большинство систем либо дороги, либо недостаточно функциональны, что обосновывает разработку собственного приложения. Рассмотрены особенности снимков Sentinel2, приводится сравнение с Landsat8/9. Перечислены основные сложности работы со снимками: спектральное смешение, сезонные вариации, атмосферные помехи и большой объём данных.

Во втором разделе "Задача классификации типов землепользования" даётся формальное определение задачи LULC (Land Use and Land Cover) как автоматическое отнесение каждого пикселя или патча к одному из заранее определённых классов. Приводится математическая постановка задачи,

перечисляются области применения, актуальные для Саратовской области: экологический мониторинг (вырубки лесов, зарастание полей, изменение береговой линии), сельское хозяйство (различение орошаемых и богарных земель), градостроительство, управление водными ресурсами и мониторинг чрезвычайных ситуаций (паводки). Описываются основные сложности при решении данной задачи: спектральное смешение (один пиксель содержит несколько типов поверхности), фенологическая изменчивость, влияние облачности и аэрозолей, а также дисбаланс классов, характерный для реальных ландшафтов.

В третьем разделе "Спектральные индексы" дается определение понятию спектральные индексы – это математические комбинации каналов, устойчивые к атмосферным эффектам и вариациям освещённости. Подробно рассматривается NDVI (нормализованный разностный вегетационный индекс), его физический смысл и диапазон значений: от отрицательных (вода) до высоких положительных (густая растительность). Указываются ограничения NDVI – насыщение при высокой биомассе и чувствительность к почвенному фону. Описывается NDWI в двух вариантах: для выделения открытых вод (зелёный и NIR) и для оценки влажности растительности (NIR и SWIR). Для урбанизированных территорий вводится индекс NDBI, основанный на разнице между SWIR и NIR. Подчёркивается необходимость правильной идентификации каналов в датасете (например, B4 – красный, B8 – NIR). Для оценки информативности индексов предлагается использовать Fкритерий ANOVA. Кроме индексов, в качестве признаков предлагается использовать статистические характеристики (среднее, стандартное отклонение, процентиля), которые повышают разделимость классов.

В четвертом разделе "Методы машинного обучения для классификации" рассматриваются основные алгоритмы: логистическая регрессия (с сигмной и softmax для многоклассового случая), метод опорных векторов (SVM) с поиском оптимальной разделяющей гиперплоскости, деревья решений с критерием Джини и их ансамбль –

случайный лес. Основное внимание уделено градиентному бустингу, а именно трём реализациям: XGBoost (с регуляризацией и учётом производных второго порядка), LightGBM (гистограммный подход, рост по листьям) и CatBoost (упорядоченный бустинг, работа с категориальными признаками). Описывается принцип ансамблирования через мягкое голосование, когда усредняются вероятности классов, что часто даёт более высокую точность, чем жёсткое голосование. Для оценки качества моделей вводятся метрики: Accuracy, Precision, Recall, F1score, а также их макро и взвешенные варианты для многоклассовой задачи. Приводится сравнительная таблица алгоритмов по устойчивости к шуму, дисбалансу и интерпретируемости, показывающая, что ансамбли градиентного бустинга наиболее эффективны для спутниковых данных.

Пятый раздел "Глубокое обучение для сегментации спутниковых снимков" посвящен описанию основных архитектур, которые используются для решения задач сегментации. В качестве эталонной архитектуры представлена UNet, которая благодаря симметричной структуре энкодер-декодер и горизонтальным пропускным соединениям эффективно восстанавливает пространственные детали. В качестве основы энкодера выбран EfficientNetB0 – он обеспечивает хороший баланс точности и производительности. Для подачи в сеть все 12 каналов Sentinel2 приводятся к единому разрешению 10 м (каналы 20 и 60 м повышаются интерполяцией). Выходной слой использует свёртку 1×1 и функцию softmax для получения вероятностей классов для каждого пикселя. Из-за сильного дисбаланса классов вместо кроссэнтропии применяется Dice Loss, которая инвариантна к размеру объекта и способствует более равномерному обучению. В качестве метрик качества используются Pixel Accuracy, IoU (Intersection over Union) и Dice Score.

В шестом разделе "Предобработка данных и борьба с дисбалансом классов" подготовка данных для применения методов машинного обучения. Сначала устраняются пропуски, которые заполняются медианными

значениями внутри каждого класса, чтобы сохранить специфику распределений. Для обнаружения и обработки выбросов применяется метод межквартильного размаха (IQR) с коэффициентом 1.5,. Затем выполняется нормализация (линейное масштабирование в $[0,1]$) или стандартизация (Zпреобразование) в зависимости от модели; для нейросетей используется поканальная нормализация по среднему и стандартному отклонению. Рассматривается проблема дисбаланса классов: мажорные классы (лес, пашня) доминируют, а минорные (пруды, городская застройка) представлены слабо, что ведёт к игнорированию редких классов. Для борьбы с дисбалансом предлагаются три подхода: взвешивание классов в функции потерь (вес обратно пропорционален частоте), оверсэмплинг (дублирование редких классов) и андерсэмплинг (уменьшение мажорных).

В седьмом разделе "Анализ исходного датасета" даётся описание восьми классов землепользования для Среднего Поволжья с их спектральными сигнатурами (водохранилища, пруды, леса, пашня, орошение, богара, город, село). Исходный датасет от географического факультета содержит 2252 строки (пикселя) и 10 каналов. После удаления дублей и обработки пропусков медианами, а также ограничения выбросов по IQR, проведён разведочный анализ, выявивший сильный дисбаланс классов и мультиколлинеарность (VIF для B10 и B11 критически высок). PCA показывает, что первые две компоненты объясняют 98,4 % дисперсии. Проведена инженерия признаков – расчёт спектральных индексов NDVI, NDBI и др., которые статистически значимо различают классы (по Fкритерию). Обучены четыре модели, лучшей оказался XGBoost (Accuracy 0,74, F1 0,74). Далее описывается процесс ручной разметки 300 снимков в QGIS, на основе которых обучены ансамбль (CatBoost+XGBoost+LightGBM) на патчах 64×64 (F1=0,73) и модель сегментации UNet (Pixel Accuracy 0,73). Приведены метрики по классам, матрица ошибок и сравнение размера патча (оптимальным признан 64×64).

Восьмой раздел "Разработка десктопприложения" посвящен описанию

архитектуры созданного приложения, которое обеспечивает практическое применение разработанных моделей без необходимости программирования. Приложение имеет три вкладки: «Классификация» (патчевая ансамблем), «Сегментация» (попиксельная UNet) и «RGBпросмотр» (отображение естественных цветов). Модуль классификации загружает GeoTIFF, нарезает его на патчи 64×64, вычисляет для каждого статистические признаки и индексы, затем выполняет предсказание ансамблем с мягким голосованием и выводит таблицу с распределением классов. Модуль сегментации принимает 12канальный снимок, нормализует его и запускает инференс UNet, после чего отображает цветную карту классов и статистику площадей. Модуль RGB формирует композит из каналов B4, B3, B2 с перцентильной нормализацией для естественной цветопередачи. Все длительные операции выполняются в отдельных потоках, не блокируя интерфейс. Приложение собрано в автономный EXEфайл с помощью PyInstaller (размер около 2,8 ГБ), включающий все зависимости и обученные модели. Для корректной работы при разных сценариях (разработка и сборка) реализовано автоматическое определение путей к ресурсам. Приложение не требует установки Python или доступа в интернет и готово к использованию в полевых условиях.

ЗАКЛЮЧЕНИЕ

В процессе выполнения магистерской работы все сформулированные во введении задачи решены в полном объёме. Проведён обзор существующих методов классификации по спутниковым данным, изучены спектральные характеристики каналов Sentinel-2 и информативность спектральных индексов, после чего была выполнена предобработка и разведочный анализ предоставленного табличного датасета, а также проведена ручная разметка 300 снимков Sentinel-2 L2A. Разработаны и обучены две модели: ансамбль градиентного бустинга для классификации патчей 64×64 пикселя и U-Net с энкодером EfficientNet-B0 для попиксельной сегментации. Оценка точности выполнена на отложенной тестовой выборке по метрикам Accuracy, F1-score

и IoU. Реализовано десктоп-приложение с графическим интерфейсом, объединяющее три режима работы. Проведён анализ исходного табличного датасета географического факультета из 2252 значений изолированных пикселей и 10 спектральных каналов B1, B2, B3, B4, B5, B6, B7, B8, B9, B10, B11. Показано, что модель XGBoost, достигшая Accuracy 0,74 на тестовой выборке, при переносе на растровый снимок даёт систематические ошибки и обладает слабой предсказательной способностью. Установлено, что классификация изолированных пикселей без пространственного контекста непригодна для работы с растровыми данными, что обосновывает необходимость ручной разметки.

Создан размеченный набор данных на основе полных 12-канальных снимков Sentinel-2 L2A для территории Среднего Поволжья.

Разработаны две модели. Ансамбль CatBoost, XGBoost и LightGBM с мягким голосованием классифицирует патчи 64×64 . U-Net с энкодером EfficientNet-B0 выполняет попиксельную сегментацию. Обучение проводилось с Dice Loss. Pixel Accuracy сегментационной модели составила 0,73. Наилучшие результаты получены для пашни ($F1 = 0,87$) и водохранилища ($F1 = 0,82$), наихудшие — для орошения ($F1 = 0,59$). Основная путаница наблюдается между спектрально схожими классами. Полученная точность сегментации (Pixel Accuracy = 0,73) сопоставима с результатами современных работ. Согласно обзору Josea et al. [32], средняя точность классификации по данным Sentinel-2 для 6–8 классов составляет 0,70–0,75. Разработанный ансамбль градиентного бустинга показал $F1 = 0,73$, что находится на уровне лучших табличных методов [21–23].

Реализовано десктоп-приложение с тремя режимами: классификация патчей, сегментация и RGB-визуализация. Приложение собрано в автономный EXE-файл (PyInstaller, 2,8 ГБ), не требующий установки Python и доступа к интернету.

Разработанное приложение предназначено для автоматической классификации и сегментации типов землепользования по одному снимку

Sentinel-2 L2A.

Результаты работы представлены на студенческой научной конференции факультета компьютерных наук и информационных технологий.

Основные источники информации

1. Meskour B., Hssaisoune M., Labbaci A., Dadi Y., Bouslihim Y. Predicting land use land cover dynamics using machine learning and satellite imagery: A case study // *Ecological Engineering & Environmental Technology*. 2025. V. 26. No. 8. P. 329–341. DOI: 10.12912/27197050/207282.

2. Carvalho M., Cardoso-Fernandes J., González F. J., Teodoro A. C. Comparative Performance of Sentinel-2 and Landsat-9 Data for Raw Materials' Exploration Onshore and in Coastal Areas // *Remote Sensing*. 2025. Vol. 17, No. 2. P. 305. DOI: 10.3390/rs17020305.

3. Самсонов А. А., Чуриков Ю. А., Анисимов Н. Н., Ибрагимов А. Р. Особенности применения дистанционного зондирования Земли для решения геологических задач в природных зонах Российской Федерации // *Вестник Московского университета. Серия 4. Геология*. 2025. № 3. С. 44–52.

4. Гонсалес-Рамирес А., Атцбергер К., Торрес-Роман Д., Лопес Х. Representation Learning of Multi-Spectral Earth Observation Time Series and Evaluation for Crop Type Classification // *Remote Sensing*. 2025. Vol. 17, No. 3. P. 378. DOI: 10.3390/rs17030378.

5. Chen Q., Vaudour E., Richer-de-Forges A. C., Arrouays D. Spectral indices in remote sensing of soil: definition, popularity, and issues. A critical overview // *Remote Sensing of Environment*. 2025. Vol. 329. Art. 114918. DOI: 10.1016/j.rse.2025.114918.

6. Денисова Н., Петрова О., Zhussupova G., Чепашев Д. Интеграция машинного обучения и данных ДЗЗ для картирования растительности в пределах лавиноопасных территорий ВКО // *Вестник Алматинского университета энергетики и связи*. 2025. Т. 70. № 3. С. 178–190. DOI: 10.51775/2790-0886_2025_70_3_178.

7. Rawan S. A., Rodriguez-Villegas E. A comparative study in class imbalance mitigation when working with physiological signals // *Frontiers*. 2024. Vol. 6
8. Da Poian V., Theiling B., Clough L., McKinney B., Major J., Jingyi C., Hörst S. Exploratory data analysis (EDA) machine learning approaches for ocean world analog mass spectrometry // *Frontiers in Astronomy and Space Sciences*. 2023. Vol. 10.
9. Chen H., He Y., Zhang L., Yang W., Liu Y., Gao B., Zhang Q., Lu J. A Multi-Input Channel U-Net Landslide Detection Method Fusing SAR Multisource Remote Sensing Data // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2023. Vol. 17. P. 1215–1232. DOI: 10.1109/JSTARS.2023.3339294.
10. Abbas H., Tao W., Khan G., Alrefaei A. F., Iqbal J., Albeshr M. F. et al. Multilayer perceptron and Markov chain analysis-based hybrid-approach for predicting land use land cover change dynamics with Sentinel-2 imagery // *Geocarto International*. 2023. Vol. 38, No. 1. Art. 2256297. DOI: 10.1080/10106049.2023.2256297.