

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение  
высшего образования

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

Кафедра информатики и программирования

**КЛАССИФИКАЦИЯ СПУТНИКОВЫХ СНИМКОВ ДЛЯ  
ОПРЕДЕЛЕНИЯ ТИПА ТЕРРИТОРИИ ПО СОСТОЯНИЮ  
ЗАРАСТАЕМОСТИ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ  
АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ**

студентки 2 курса 273 группы  
направления 02.03.04 Математическое обеспечение и администрирование  
информационных систем  
факультета компьютерных наук и информационных технологий  
Коноплевой Алены Игоревны

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

**Актуальность темы.** В современном мире антропогенное воздействие на окружающую среду приобретает всё более значительные масштабы, что обуславливает необходимость рационального использования земельных ресурсов. Мониторинг состояния территорий приобретает ключевое значение для разработки эффективных стратегий по сохранению экосистем и минимизации негативных последствий человеческой деятельности.

Данные дистанционного зондирования Земли (ДЗЗ) являются основным источником актуальной и достоверной информации о состоянии земной поверхности и широко применяются для решения задач экологического мониторинга, картографирования землепользования, оценки состояния лесных и сельскохозяйственных угодий, а также прогнозирования изменений ландшафтов под воздействием природных и антропогенных факторов.

Особую актуальность задача мониторинга земель приобретает в Российской Федерации, где значительная часть сельскохозяйственных угодий, выведенных из оборота в 1990-х годах, подверглась процессу естественной сукцессии и постепенному зарастанию древесно-кустарниковой растительностью. Согласно Федеральному закону от 24.07.2002 № 101-ФЗ «Об обороте земель сельскохозяйственного назначения», такие земли подлежат обязательному учёту и регулярному мониторингу, а длительно не возделываемые участки могут быть изъяты у собственника. Традиционные методы анализа, основанные на ручной интерпретации спутниковых снимков и векторизации границ территорий специалистами-географами, являются крайне трудоёмкими, ресурсозатратными и не позволяют обеспечить регулярное обновление данных по большим территориям. Развитие технологий дистанционного зондирования и методов глубокого обучения открывает новые возможности автоматизации процесса классификации территорий по спутниковым снимкам, что и определяет актуальность

настоящей работы.

Целью выпускной квалификационной работы является разработка метода автоматической классификации территорий по спутниковым снимкам с помощью глубокого обучения.

Для достижения поставленной цели в работе решаются следующие задачи:

- 1) провести анализ существующих программных решений в области автоматической классификации спутниковых снимков;
- 2) проанализировать особенности работы со спутниковыми снимками, включая форматы хранения, типы данных и применяемые системы координат;
- 3) изучить основные архитектуры свёрточных нейронных сетей (VGG, ResNet), применяемые в задачах компьютерного зрения, а также методологию переноса обучения;
- 4) рассмотреть традиционные методы сегментации (пороговая бинаризация, методы выделения границ, кластеризация) и современные нейросетевые архитектуры семантической сегментации (SegNet, FPN, U-Net, DeepLabv3+);
- 5) изучить функции потерь и метрики оценки качества сегментации, в том числе комбинированные функции потерь для условий выраженного дисбаланса классов;
- 6) провести анализ и предобработку исходного набора данных, выполнить дополнительную разметку и сформировать обучающую выборку;
- 7) реализовать традиционные методы сегментации и оценить их применимость к поставленной задаче;
- 8) провести сравнительное обучение и тестирование нейросетевых моделей с различными архитектурами, кодировщиками и функциями потерь и определить оптимальную конфигурацию для практического применения;
- 9) применить выбранную модель к полноразмерному спутниковому снимку методом скользящего окна, выполнить векторизацию и постобработку

результатов сегментации;

10) разработать программный модуль (плагин) для геоинформационной системы QGIS, обеспечивающий полный цикл обработки спутниковых снимков с использованием обученной модели, и протестировать его работу на новых спутниковых данных.

**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). Вопросы переноса обучения и переносимости признаков глубоких сетей рассмотрены в работах С. Дж. Пана (S. J. Pan) и Дж. Йосински (J. Yosinski). 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.

**Теоретическая значимость** состоит в проведённом сравнительном анализе нейросетевых архитектур семантической сегментации (U-Net, FPN, DeepLabv3+) с различными кодировщиками и комбинированными функциями потерь применительно к специфической задаче классификации постсоветских сельскохозяйственных земель по стадиям зарастания в условиях выраженного дисбаланса классов и работы с трёхканальными (RGB) спутниковыми снимками.

**Практическая значимость магистерской работы** заключается в создании готового программного инструмента — плагина для открытой геоинформационной системы QGIS, обеспечивающего полный цикл обработки спутникового снимка: от загрузки растрового слоя в проект до получения векторного слоя сегментации с заполненной атрибутивной таблицей. Разработанный инструмент позволяет автоматизировать трудоёмкий процесс ручной векторизации территорий по состоянию

зарастаемости и может быть использован для мониторинга земель сельскохозяйственного назначения, анализа изменений ландшафтов и поддержки принятия решений в области природопользования. 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, семи разделов, заключения, списка использованных источников и шести приложений. Общий объём работы — 115 страниц, из них 72 страницы — основное содержание, включая 19 рисунков и 6 таблиц, цифровой носитель в качестве приложения. Список использованных источников информации — 49 наименований.

## **КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ**

**Первый раздел «Дистанционное зондирование Земли и спутниковые данные»** посвящён базовым понятиям предметной области. Рассмотрены принципы дистанционного зондирования Земли, типы сенсоров и методов съёмки, особенности работы с многоканальными и трёхканальными (RGB) спутниковыми снимками, индексные методы оценки растительности (NDVI). Отмечено, что в условиях отсутствия мультиспектральных данных приходится работать с трёхканальными изображениями, что ограничивает возможности детального спектрального анализа и требует опоры на пространственно-текстурные признаки. Описаны распространённые форматы хранения геопространственных данных (GeoTIFF, Shapefile) и роль геоинформационных систем, в первую очередь открытой платформы QGIS, в задачах анализа территорий. Отдельно охарактеризована операция векторизации как трудоёмкого ручного процесса, автоматизации которого посвящена работа.

По результатам раздела сделан вывод о том, что трёхканальные снимки высокого пространственного разрешения в сочетании с открытой

расширяемой платформой QGIS представляют собой практически доступную основу для построения автоматизированного инструмента классификации территорий, не требующего дорогостоящих мультиспектральных данных.

**Второй и третий разделы** «Проблема автоматического определения типа территории» и «Современные решения для автоматического определения типа территории» формулируют решаемую проблему и содержат обзор предметной области. Обоснована актуальность задачи классификации земель по состоянию зарастаемости (поле, залежь, редкие кусты, редкие деревья, лес) для условий Российской Федерации. Проанализированы научные исследования по классификации типов землепользования, а также программные решения двух групп: коммерческие платформы (сервис «ИнноГеоТех» и Иннополиса, ArcGIS Pro с расширением Image Analyst) и открытые расширения QGIS. Подробно рассмотрен наиболее близкий аналог — плагин Deepness; показано, что его универсальный набор классов не предусматривает подкатегорий древесно-кустарниковой растительности по стадиям зарастания и не обеспечивает автоматическую запись атрибутов, необходимых для задач мониторинга земель, что обосновывает разработку специализированного решения.

**Четвёртый, пятый и шестой разделы** образуют теоретическую основу работы. В разделе «Классификация изображений» рассмотрены принципы свёрточных нейронных сетей, базовые операции свёртки, активации и пулинга, архитектуры VGG и ResNet, проблема затухания градиента и остаточные связи (residual connections), позволяющие обучать сети глубиной 50 и более слоёв, а также методология переноса обучения с предобученных на ImageNet моделей. Раздел «Сегментация изображений» содержит обзор традиционных методов (пороговая бинаризация методом Оцу, выделение границ операторами Собеля и Кэнни, кластеризация K-means) и современных нейросетевых архитектур семантической сегментации (SegNet, FPN, U-Net, DeepLabv3+); особое внимание уделено модулю атрусной пространственной пирамиды (Atrous Spatial Pyramid

Pooling) архитектуры DeepLabv3+, обеспечивающему захват многомасштабного контекста. В разделе «Функции потерь и метрики оценки качества сегментации» рассмотрены кросс-энтропийная функция потерь, Dice Loss и комбинированные функции потерь (ComboLoss, WeightedComboLoss), а также метрики качества Dice, IoU, Pixel Accuracy и F1-score, и обоснован выбор метрик, устойчивых к дисбалансу классов.

Анализ теоретического материала позволил обоснованно сформировать конфигурацию для практических экспериментов: использование предобученных кодировщиков семейства ResNet в составе архитектур кодер-декодер и комбинированных функций потерь как наиболее перспективного подхода для условий ограниченного объёма размеченных данных и выраженного дисбаланса классов.

**Седьмой раздел «Практическая часть»** составляет основное содержание работы и описывает выполненные исследования и разработку.

На этапе анализа и предобработки данных исследован полноразмерный трёхканальный спутниковый снимок территории Саратовской области и предоставленная географами векторная разметка. На основе анализа распределения классов был выявлен существенный дисбаланс: доминирующий класс «Поле» по покрываемой площади превосходит редкие классы (переувлажнённые и заболоченные территории, элемент ОБС) в отдельных случаях более чем на четыре порядка. Для смягчения дисбаланса и увеличения объёма обучающих данных исходный набор векторных данных был расширен путём дополнительной разметки с 1870 до 3460 полигонов. После разрезки изображения на фрагменты размером 224×224 пикселя с перекрытием и фильтрации неинформативных фрагментов был сформирован обучающий датасет из 2972 пар «изображение — маска» для восьми целевых классов. На основе векторных слоёв построены растровые маски классов, применена аугментация данных.

Реализованы и оценены традиционные методы сегментации (пороговая сегментация методом Оцу, покомпонентная пороговая сегментация,

выделение границ оператором Кэнни, кластеризация K-means). Установлено, что данные подходы имеют ограниченную точность при работе с неоднородными и мультиклассовыми спутниковыми изображениями, поскольку не учитывают пространственный контекст и не способны различать визуально близкие, но семантически разные классы.

Проведено сравнительное обучение нейросетевых моделей. На первом этапе сопоставлялись архитектуры U-Net и FPN с тремя кодировщиками (ResNet18, ResNet50, VGG16), инициализированными весами ImageNet. Архитектура U-Net продемонстрировала стабильное превосходство над FPN по всем основным метрикам, а комбинация U-Net + ResNet50 обеспечила наилучшее соотношение точности, стабильности и вычислительных затрат и была выбрана базовой.

На втором этапе на расширенной выборке выполнено сравнение комбинированных функций потерь. Сравнение продемонстрировало преимущество ComboLoss над WeightedComboLoss по всем основным метрикам качества (Dice 0,77 против 0,64; IoU 0,73 против 0,58; F1 0,84 против 0,71). Показано, что взвешивание классов в WeightedComboLoss привело к переусилению вклада редких классов и ухудшению оптимизации границ сегментов, тогда как ComboLoss обеспечивает оптимальный баланс между пиксельной точностью (Cross-Entropy) и качеством пространственного перекрытия сегментов (Dice Loss).

Финальное сравнение архитектур U-Net и DeepLabv3+ с предобученным кодировщиком ResNet50 и функцией потерь ComboLoss показало превосходство DeepLabv3+ для большинства классов за счёт применения модуля атрусной пространственной пирамиды (ASPP), позволяющего охватывать широкий пространственный контекст. Наиболее заметное улучшение достигнуто для сложно различимых классов древесно-кустарниковой растительности с нечёткими границами и высокой внутриклассовой вариативностью. Наилучшее качество по отдельным классам достигнуто для класса «Поле» (Dice 0,931); итоговые показатели на

тестовой выборке составили Dice 0,779, IoU 0,738 и F1 0,843. Визуальный анализ предсказаний подтвердил количественные выводы: модель корректно выделяет границы объектов и в ряде случаев обнаруживает объекты, не отмеченные в исходной ручной разметке.

Оптимальная модель DeepLabv3+ совместно с ComboLoss была применена к полноразмерному спутниковому снимку методом скользящего окна с усреднением вероятностей в зонах перекрытия, после чего полученная растровая карта была векторизована в формат GeoPackage с фильтрацией мелких полигонов и формированием атрибутивной таблицы.

В завершении разработан плагин для геоинформационной системы QGIS, обеспечивающий полный цикл обработки спутникового снимка — от его загрузки в проект до получения векторного слоя сегментации с заполненными атрибутами. Плагин использует многопоточную обработку для сохранения отзывчивости интерфейса при работе с крупными снимками и протестирован на новых спутниковых данных. Описаны функциональные возможности, архитектура и порядок использования плагина.

## **ЗАКЛЮЧЕНИЕ**

В ходе данной работы был проведён анализ современных научных исследований и программных расширений геоинформационных систем для автоматического определения типа территории, изучены особенности работы со спутниковыми снимками и форматы их хранения.

Для классификации изображений были рассмотрены различные архитектуры свёрточных нейронных сетей, такие как VGG и ResNet, а также методология переноса обучения с использованием предобученных моделей.

Для сегментации изображений были рассмотрены традиционные методы: пороговая бинаризация методом Оцу, выделение границ оператором Кэнни и кластеризация K-means, а также современные подходы на основе глубокого обучения, включая архитектуры SegNet, FPN, U-Net и DeepLabv3+. Изучены функции потерь и метрики оценки качества сегментации, в том

числе комбинированные функции потерь для условий выраженного дисбаланса классов.

В рамках практической части работы проведены анализ и предобработка исходных данных. Исходный набор векторных данных был расширен путём дополнительной разметки с 1870 до 3460 полигонов. После разрезки изображения на фрагменты размером 224×224 пикселя с перекрытием и фильтрации неинформативных фрагментов сформирован обучающий датасет из 2972 пар «изображение — маска» для восьми целевых классов.

На первом этапе были исследованы традиционные методы сегментации. Установлено, что данные подходы имеют ограниченную точность при работе с неоднородными и мультиклассовыми спутниковыми изображениями, поскольку не учитывают пространственный контекст и не способны различать визуально близкие, но семантически разные классы.

На следующем этапе проведено сравнительное обучение нейросетевых моделей. В эксперименте с архитектурами U-Net и FPN с различными кодировщиками (ResNet18, ResNet50, VGG16) наилучшие результаты показала комбинация U-Net + ResNet50. Сравнение функций потерь продемонстрировало преимущество ComboLoss над WeightedComboLoss по всем основным метрикам качества (Dice 0,77 против 0,64; IoU 0,73 против 0,58; F1 0,84 против 0,71). Финальное сравнение архитектур U-Net и DeepLabv3+ с предобученным кодировщиком ResNet50 и функцией потерь ComboLoss показало превосходство DeepLabv3+ для большинства классов за счёт применения модуля Atrous Spatial Pyramid Pooling.

Оптимальная модель DeepLabv3+ совместно с ComboLoss была применена к полноразмерному спутниковому снимку методом скользящего окна с усреднением вероятностей в зонах перекрытия, после чего полученная растровая карта была векторизована в формат GeoPackage с фильтрацией мелких полигонов и формированием атрибутивной таблицы.

В завершение разработан плагин для геоинформационной системы

QGIS, обеспечивающий полный цикл обработки спутникового снимка — от его загрузки в проект до получения векторного слоя сегментации с заполненными атрибутами. Плагин использует многопоточную обработку для сохранения отзывчивости интерфейса при работе с крупными снимками.

Таким образом, поставленные в рамках магистерской работы задачи были успешно решены.

**Отдельные части магистерской работы были опубликованы /  
представлены на конференции**

Результаты работы представлены на студенческой научной конференции (I место). Подготовлена статья, принятая к печати:

Классификация типов территорий по состоянию зарастаемости на основе сегментации спутниковых изображений методами глубокого обучения / М. В. Огнева, П. А. Шлапак, А. И. Коноплева // Известия Саратовского университета. — 2026. (принято к печати).

**Основные источники информации**

1. Image Segmentation Using Deep Learning: A Survey / S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, D. Terzopoulos // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 2022. — Vol. 44, no. 7. — P. 3523–3542.
2. Ronneberger, O. U-Net: Convolutional Networks for Biomedical Image Segmentation / O. Ronneberger, P. Fischer, T. Brox // Lecture Notes in Computer Science. — 2015. — P. 234–241.
3. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation / L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, H. Adam // Proceedings of the European Conference on Computer Vision (ECCV). — 2018. — P. 833–851.
4. Deep Residual Learning for Image Recognition / K. He, X. Zhang, S. Ren, J. Sun // Proceedings of the IEEE Conference on Computer Vision and Pattern

- Recognition (CVPR). — 2016. — P. 770–778.
5. Simonyan, K. Very Deep Convolutional Networks for Large-Scale Image Recognition / K. Simonyan, A. Zisserman // International Conference on Learning Representations (ICLR). — 2015.
  6. Krizhevsky, A. ImageNet Classification with Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, G. E. Hinton // Advances in Neural Information Processing Systems. — 2012. — P. 1097–1105.
  7. Adegun, A. A. Review of deep learning methods for remote sensing satellite images classification: experimental survey and comparative analysis / A. A. Adegun, S. Viriri, J. R. Tapamo // Journal of Big Data. — 2023. — No. 93.
  8. Phiri, D. Sentinel-2 Data for Land Cover/Use Mapping: A Review / D. Phiri, M. Simwanda, S. Salekin // Remote Sensing. — 2020. — Vol. 12, no. 14.
  9. Taghanaki, S. Combo loss: Handling input and output imbalance in multi-organ segmentation / S. Taghanaki, Y. Zheng, K. Zhou // Computerized Medical Imaging and Graphics. — 2019. — P. 24–33.
  10. Pan, S. J. A Survey on Transfer Learning / S. J. Pan, Q. Yang // IEEE Transactions on Knowledge and Data Engineering. — 2010. — Vol. 22, no. 10. — P. 1345–1359.