МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

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

Кафедра геоморфологии и геоэкологии

**Автоматизированное дешифрирование типов
землепользования с использованием методов машинного
обучения (на примере города Саратова)**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студента 4 курса 431 группы

направления 05.03.03 Картография и геоинформатика

географического факультета

Дувакина Дмитрия Андреевича

Научный руководитель
старший преподаватель

В.А. Морозова

инициалы, фамилия

Зав. кафедрой
к.с-х.н., доцент

В.А. Гусев

инициалы, фамилия

Саратов 2025

Введение. Территориальное планирование требует применения инновационных подходов, которые способны обеспечить как высокую точность, так и оперативность анализа поступающих пространственных данных. Эффективное решение задачи автоматизированного дешифрирования с использованием методов машинного обучения обеспечит основу для рационального использования территорий, а также для мониторинга и стратегического планирования.

Объектом и предметом данного исследования являются типы землепользования, а также методы и технологии, используемые для их классификации. С использованием геоинформационных технологий и методов машинного обучения мы стремимся разработать эффективные подходы к анализу и автоматической классификации земельных участков на основе данных дистанционного зондирования.

Актуальность данного исследования обусловлена растущим интересом к проблемам устойчивого территориального развития, рационального использования природных ресурсов и охране окружающей среды. Развитие методов анализа пространственных данных с применением машинного обучения открывает новые возможности для эффективного мониторинга и управления землепользованием, включая сферы использования типов землепользования, такие как сельское и лесное хозяйство, градостроительство и экология.

Целью данной работы является подбор и оценка эффективного метода классификации типов землепользования с использованием ГИС-технологий и методов машинного обучения.

Для достижения этой цели были поставлены следующие задачи:

- Сбор и обработка спутниковых данных SENTINEL-2 на территорию города Саратова с помощью ГИС-технологий;
- Анализ и оценка существующих алгоритмов машинного обучения в рамках классификации изображений;
- Использование методов машинного обучения на языке

программирования Python для обучения моделей классификации;

- Оценка качества классификации типов землепользования, анализ полученных результатов;

- Подготовка данных для выгрузки на ВЕБ-платформу для обеспечения доступности и поддержки принятия решений.

Структура работы: работа состоит из трёх разделов, заключения, списка использованных источников, приложений.

Структура работы:

1. Роль данных дистанционного зондирования в землепользовании и территориальном планировании

Дистанционное зондирование Земли (ДЗЗ) представляет собой получение информации о поверхности Земли и объектах на ней, атмосфере, океане, верхнем слое земной коры бесконтактными методами, которые подразумевают, что регистрирующий прибор удален от объекта исследований на значительное расстояние [1].

Данные дистанционного зондирования способны быть достаточно точной основой для мониторинга землепользования, поскольку они представляют собой самые актуальные пространственные данные, причем в большом объеме, ввиду чего и возможен контроль функционального зонирования территорий.

Использование данных ДЗЗ перспективно и в случае оценки городских территорий, поскольку от принятия обоснованных, эффективных решений по функциональному зонированию территории при разработке генерального плана города зависит протекание в нем всех процессов жизнедеятельности населения, производства, размещения элементов инфраструктуры [2].

Спутниковые данные представляют собой цифровое изображение, в геоинформационных системах для представления цифровых изображения используется растровая модель данных.

Растровая модель представляет геометрию пространственных объектов в виде совокупности ячеек растра (пикселей). Значения ячеек могут

быть результатами измерений.

Если атомарной единицей данных при их описании служит элемент «разбиения» территории — регулярная пространственная ячейка (территориальная ячейка) правильной геометрической формы — речь идет о другой, отличной от растровой, хотя и формально с нею схожей, регулярно-ячейистой модели данных [3].

Дешифрирование снимков, определяемое как процесс распознавания объектов, их свойств и взаимосвязей по их изображениям, или более полно — изучение территорий на основе зависимости между свойствами объектов и характером их воспроизведения на снимках, является ключевым этапом в применении аэрокосмических данных для анализа землепользования [4].

Классификация позволяет автоматически разбивать снимки на однородные области (классы объектов) на основе анализа их характеристик, чаще всего спектральных образов (сигнатур), получая в итоге тематическую карту.

Функциональное зонирование является ключевым элементом территориального планирования, направленным на определение функционального назначения территорий поселения (его отдельных территорий) [2]. Это определение основывается на совокупности социальных, экономических, экологических и иных факторов. Карта градостроительного зонирования относится к числу наиболее значимых документов, максимально влияющих на развитие города.

Примером функциональных зон или территорий градостроительного развития и функционального преобразования могут послужить: жилые зоны, общественно-деловые зоны, зоны инженерной и транспортной инфраструктуры, производственные зоны, зоны сельскохозяйственного использования и прочие.

2. Автоматизированное дешифрирование методами ГИС и машинного обучения

Использование современных геопорталов и программных инструментов, таких как геоинформационный пакет QGIS и библиотеки языка программирования Python, упрощает доступ к данным и их обработку, делая технологии дешифрирования более доступными и универсальными.

Машинное обучение – это раздел искусственного интеллекта, который обучает компьютерные системы самостоятельно улучшать свои результаты на основе опыта. С развитием спутниковых технологий и датчиков, собирающих огромные объемы данных о поверхности Земли, возникает потребность в эффективных методах анализа и интерпретации этой информации.

Наибольшую эффективность демонстрируют алгоритмы машинного обучения, реализующие автоматизацию процессов принятия решений посредством генерализации на основе обучающей выборки. В рамках парадигмы обучения с учителем (supervised learning) система получает набор прецедентов в форме пар "входные данные - целевое значение", на основе которых формируется решающая функция. Ключевой характеристикой таких алгоритмов является способность к обобщению - генерации прогнозных значений для ранее не встречавшихся объектов без необходимости дополнительного вмешательства оператора. [5].

Геопортал – это ВЕБ-среда, которая позволяет организации или сообществу пользователей и поставщиков информации объединять контент и обмениваться им, а также создавать согласованность [6]. Они служат важным источником информации для различных приложений, включая картографирование, мониторинг окружающей среды, сельское хозяйство, лесное хозяйство и многое другое.

Одним из таких геопорталов является EOBrowser [7], который позволяет просматривать и сравнивать спутниковые снимки в полном разрешении на выбранную область. Платформа геопортала предоставляет возможность скачивания и обработки снимков поканально, в результате загрузки получается 13 файлов, которые в названии имеют дату, имя спутниковой системы и сам канал космоснимка.

Для синтеза каналов было использовано программное обеспечение, QGIS 3.28. Для этого были импортированы данные каналов и созданы виртуальные растры, после чего на вход подавались отдельные растры, представляющие спектральные каналы данных SENTINEL-2.

После дешифрирования спутникового снимка полученные данные были подготовлены для последующего анализа средствами языка программирования Python. Для этого использовались атрибутивные значения каждого канала на определенную единицу площади, эмпирическим путем был выбран размер в 30 м.

В результате был получен shape-файл, который содержит геометрию в виде точек, каждая точка несет в себе атрибут типа землепользования, который представлен полем *type* с типом *int*, а также 13 колонок, которые отвечают на спектральные характеристики каждого канала.

3. Использование машинного обучения для классификации типов землепользования и функционального зонирования

Разведочный анализ данных – анализ основных свойств данных, нахождение в них общих закономерностей, распределений и аномалий, построение начальных моделей, зачастую с использованием инструментов визуализации [8].

В рамках данной работы было решено проводить разведочный анализ средствами языка программирования Python, в частности библиотек `numpy`, `pandas`, а также `matplotlib` и `seaborn` для визуализации данных. Работа проводилась в JupyterNotebook 7, поскольку это удобная среда разработки с предустановленными библиотеками, которые будут использоваться в данной работе.

JupyterNotebook — это упрощенное приложение для создания записных книжек, входящее в состав Project Jupyter [9]. После загрузки набора данных была построена матрица корреляций между каналами.

Матрица корреляций – это таблица, показывающая корреляционные коэффициенты между переменными в наборе данных. Корреляционный

коэффициент измеряет степень линейной зависимости между двумя переменными.

Корреляция между признаками и целевой переменной (типом землепользования) имеет большое значение для выбора признаков для классификации. Для принятия решения о том, какие каналы оставить, следует учитывать несколько факторов – это корреляция с целевой переменной и избегание мультиколлинеарности.

Для проведения исследования использовалась **карта функционального зонирования территории муниципального образования «Город Саратов»** [10], представленная в формате растрового изображения, где различные цвета соответствуют различным функциональным зонам, таким образом картографический материал использовался для подготовки набора данных, связывающего спектральные и текстурные характеристики подстилающей поверхности с её функциональным назначением.

Из всего многообразия функциональных зон, представленных в градостроительном плане, для апробации методики был выделен набор из шести ключевых классов.

Выбор обусловлен их доминирующей ролью в структуре города и предполагаемой различимостью их физических характеристик на спутниковых снимках. В исследование были включены следующие классы: водные поверхности, жилые зоны (Ж-1, Ж-2, Ж-4, Ж-5), общественно-деловые зоны (ОД-1, ОД-2, ОД-3, ОД-4, ОД-5), производственные зоны (П-1, П-2, П-3, Т-1, Т-3, И-1), рекреационные зоны (Р-1, Р-2, Р-3) и сельскохозяйственные зоны (СХ-1, СХ-2, СХ-3). Менее представленные или специфические категории были исключены из рассмотрения.

Для последующего анализа была сформирована регулярная сетка точек, охватывающая всю исследуемую территорию, с использованием инструментов пространственного анализа QGIS для каждой точки сетки были извлечены два типа информации – функциональная зона на основе цветового кода, а также спектральные значения каналов спутникового снимка SENTINEL-2.

Мультиспектральный снимок Sentinel-2 с уровнем обработки L2A был выбран безоблачный снимок за летний вегетационный период (июль), дата которого максимально близка к периоду актуальности карты функционального зонирования [11].

Для повышения точности классификации исходное признаковое пространство, состоящее только из спектральных каналов, было расширено за счет добавления текстурных характеристик. Текстура является важным дескриптором пространственной организации изображения и позволяет различать такие классы, как малоэтажная жилая застройка (неоднородная текстура) и крупные промышленные объекты (однородная текстура).

Для извлечения текстурных признаков был использован метод сероуровневой матрицы смежности (Gray-Level Co-occurrence Matrix, GLCM). На основе GLCM были рассчитаны четыре ключевых текстурных признака: контраст, однородность, энергия и корреляция.

Итоговое признаковое пространство для каждой точки выборки включило в себя 12 спектральных каналов SENTINEL-2 и 4 текстурных признака GLCM, что позволило комплексно охарактеризовать каждую точку как с точки зрения её спектрального отклика, так и пространственной структуры.

Для решения задачи мультиклассовой классификации функциональных зон были выбраны три ансамблевые модели машинного обучения, известные своей высокой эффективностью и точностью на табличных данных: Random Forest, XGBoost и LightGBM [12]. Выбор данных моделей был обоснован результатами предшествующего исследования, в рамках которого анализировался набор данных с упрощённой целевой переменной. Вместо территориальных зон в качестве единиц классификации были выделены природные категории, а именно: урбанизированная городская территория, лесная растительность, водные объекты (акватория), открытые почвы и травянистая растительность (луга). В ходе обработки данных применялись различные алгоритмы машинного обучения. На основе оценки эффективности

моделей с точки зрения точности и вычислительных затрат было установлено, что оптимальными являются случайный лес и другие ансамблевые методы.

Сравнительный анализ метрик выявил, что RandomForest значительно превосходит LGBMClassifier и CatBoostClassifier по всем ключевым показателям, что подтверждает его эффективность для обработки сложных мультиспектральных данных с учетом текстурных признаков. Высокая точность RandomForest (0.98) по сравнению с 0.71 для LGBMClassifier и 0.56 для CatBoostClassifier подчеркивает преимущества ансамблевого подхода при работе с данными SENTINEL-2. Низкие метрики LGBMClassifier и CatBoostClassifier, особенно для жилых зон, могут быть связаны с перекрытием текстурных паттернов и необходимостью дополнительной настройки параметров, таких как глубина деревьев или скорость обучения. Таким образом, RandomForest следует считать оптимальной моделью для данной задачи, обеспечивая высокую точность и стабильность классификации, что делает его предпочтительным инструментом для дальнейшего анализа типов землепользования и оценки устойчивости геосистем.

Результаты моделирования были загружены на платформу NextGIS [13]. Обоснование размещения данных на геопортале связано с необходимостью обеспечения широкого доступа к результатам исследования, что соответствует современным требованиям открытости геоинформационных данных и их практического применения. Выкладывание данных в открытый доступ на платформе NextGIS оправдано необходимостью поддержки коллективного анализа и мониторинга, что повышает их ценность для научного сообщества и органов управления. Таким образом, размещение данных на геопортале не только усиливает их практическую применимость, но и способствует реализации принципов устойчивого развития через информированное принятие решений на основе высококачественных пространственных данных.

Заключение. Настоящая работа была посвящена разработке и апробации такого подхода, сфокусированного на автоматизированной

классификации типов землепользования на основе данных ДЗЗ и методов машинного обучения, а также на последующей интеграции полученных результатов в доступный геопортал.

В процессе работы был осуществлен сбор и обработка спутниковых данных SENTINEL-2. Были проанализированы спектральные каналы, извлечены текстурные характеристики с применением GLCM (контрастность, однородность, энергия, корреляция) для минимизации проблем, связанных с неоднородностью освещения, сезонными изменениями и необходимостью ручного дешифрирования.

Был проведен сравнительный анализ трех моделей машинного обучения — RandomForest, LGBMClassifier и CatBoostClassifier. На основе матриц ошибок и метрик качества (precision, recall, F1-score) установлено явное преимущество модели RandomForest, которая достигла точности 0.98 с макро-усредненным F1-score 0.98.

Однако у RandomForest имеются и определенные ограничения. Модель показала менее точные результаты при классификации сложных урбанизированных зон, таких как "Ж-1", где из 24088 пикселей верно распознано лишь 23672, с ошибками в сторону соседних классов, например, "Ж-4" и "Общественно-деловые зоны". Это может быть связано с перекрытием текстурных паттернов в жилых районах, что затрудняет разделение классов.

Напротив, LGBMClassifier и CatBoostClassifier показали существенно более низкие результаты с точностью 0.71 и 0.56 соответственно, что связано с трудностями в идентификации жилых зон из-за перекрытия текстурных паттернов.

Полученные результаты классификации были экспортированы в ГИС и, что особенно важно, загружены на геопортал, что обеспечивает интерактивный доступ к классифицированным данным, позволяя визуализировать и анализировать типы землепользования в удобном веб-интерфейсе. Интеграция обученных моделей напрямую в среду геопортала создает основу для оперативного предоставления актуальной

картографической информации и способствует принятию обоснованных решений в области территориального планирования, сельского и лесного хозяйства, градостроительства и экологии.

В ходе исследования были успешно выполнены все поставленные задачи, что позволило достичь основной цели работы — подобрать и оценить эффективный метод классификации типов землепользования с использованием ГИС-технологий и методов машинного обучения.

Проведенная апробация подхода позволяет не только повысить точность и оперативность классификации типов землепользования, но и предоставляет удобный инструмент для мониторинга и стратегического планирования, способствуя устойчивому развитию и рациональному использованию территории города Саратова.

Список использованных источников

1 Сутырина, Е.Н. Дистанционное зондирование земли / Е. Н. Сутырина. – М.: Иркутск: ИГУ, 2013. – 165 с.

2 Кресникова Н.И, Применение данных дистанционного зондирования и геоинформационных технологий для обеспечения территориального планирования / Н.И. Кресникова, Н.А. Васильевых // Известия высших учебных заведений. Геодезия и аэрофотосъемка. 2018. Т.62 № 2- С. 212-217.

3 Тикунов, В.С. Геоинформатика: учеб. для студ. вузов / В.С. Тикунов, Е.Г. Капралов, А.В. Кошкарев, [и др.]. – М.: Издательский центр «Академия», 2005. – 480 с.

4 Шихов А.Н. Тематическое дешифрирование и интерпретация космических снимков среднего и высокого пространственного разрешения / А.Н. Шихов, А. П. Герасимов, А. И. Пономарчук, Е. С. Перминова – М.: Пермский государственный национальный исследовательский университет, 2020. – 187 с.

5 Мюллер, А. Введение в машинное обучение с помощью Python: руководство для спец. по раб. с данными / Андреас Мюллер, Сара Гвидо. – М.: Издательский центр «Диалектика», 2022. – 480 с.

6 Maguire. David J., The emergence of geoportals and their role in spatial data infrastructures / Paul A. Longley, David J. Maguire. – М.: Department of Geography and Centre for Advanced Spatial Analysis, 2004. – 12 с.

7 EO Browser [Электронный ресурс]: EO Browser – URL: <https://apps.sentinel-hub.com/eo-browser/> (дата обращения 20.03.2025). – Загл. с экрана. – Яз.англ.

8 Кугаевских, А.В. Классические методы машинного обучения / А.В. Кугаевских, Д.И. Муромцев, О.В. Кирсанова. – М.: СПб: Университет ИТМО, 2022. – 53 с.

9 Jupyter Notebook Documentation [Электронный ресурс]: JUPYTER-NOTEBOOK.READTHEDOCS – URL: <https://jupyter-notebook.readthedocs.io/en/latest/index.html> (дата обращения 18.03.2024). – Загл. с экрана. – Яз.англ.

10 Приложение 1 к решению Саратовской городской Думы от 27 декабря 2022 года № 30-319 Генеральный план муниципального образования «Город Саратов»

11 Sentinel-2 Overview [Электронный ресурс]: SENTINEL.ESA – URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/overview> (дата обращения 14.03.2024). – Загл. с экрана. – Яз.англ.

12 Лимановская, О.В. Основы машинного обучения: учебное пособие / О.В. Лимановская, Т.И. Алферьева. – М.: Мин-во науки и высш. образования РФ — Екатеринбург: Изд-во Урал. ун-та, 2020. — 88 с.

13 Документация NextGIS Web Выпуск 3.1 [Электронный ресурс]: DOCS.NEXTGIS. – URL: https://docs.nextgis.ru/_downloads/3125bf95ca276abb0728edaf40097ac6/NextGISWeb.pdf(дата обращения 10.03.2023). – Загл. с экрана. – Яз.рус.