



Известия Саратовского университета. Новая серия. Серия: Науки о Земле. 2025. Т. 25, вып. 3. С. 194–200

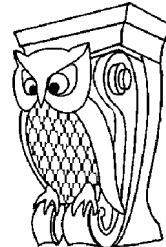
Izvestiya of Saratov University. Earth Sciences, 2025, vol. 25, iss. 3, pp. 194–200

<https://geo.sgu.ru>

<https://doi.org/10.18500/1819-7663-2025-25-3-194-200>, EDN: QMVWVB

Научная статья

УДК 630.231:528.854



Автоматическое определение лесных пород методами машинного обучения на основе обработки спутниковых снимков

М. В. Огнева, П. А. Шлапак[✉], А. А. Васильев, Д. С. Моисеев

Саратовский национальный исследовательский государственный университет имени Н. Г. Чернышевского, Россия, 410012, г. Саратов, ул. Астраханская, д. 83

Огнева Марина Валентиновна, кандидат физико-математических наук, доцент, заведующий кафедрой информатики и программирования, mv_ogneva@mail.ru, <https://orcid.org/0000-0002-9828-7681>

Шлапак Павел Александрович, старший преподаватель кафедры геоморфологии и геоэкологии, henryxiv@list.ru, <https://orcid.org/0000-0002-6418-8749>

Васильев Александр Алексеевич, магистрант факультета компьютерных наук и информационных технологий, guest838@yandex.ru, <https://orcid.org/0009-0005-2126-6427>

Моисеев Денис Сергеевич, лаборант учебной лаборатории геоинформатики и тематического картографирования, dan.moiseeff2016@yandex.ru, <https://orcid.org/0009-0007-8383-5239>

Аннотация. Мониторинг состояния и видового разнообразия древесных пород играет значительную роль в рамках менеджмента лесных ресурсов. Появление мультиспектральных спутниковых снимков высокого качества открывает возможности для использования информации о вегетации растительности на определенной территории в течение длительного периода времени, извлекаемых из фотографий, в дополнение к данным, получаемым в результате полевых исследований. В работе рассматривается использование снимков со спутника Sentinel 2 для автоматизированной разметки на примере территории памятника природы «Природный парк Кумысная Поляна», расположенного в окрестностях г. Саратова. В качестве инструментов автоматизации использовались методы машинного обучения с учителем. В работе было описано три подхода, различающиеся используемыми алгоритмами, а также способами структурирования получаемой информации со спутниковых снимков. В результате работы тестовая часть исследуемой территории была классифицирована по семи видам деревьев, включающим в себя выделы с доминированием наиболее распространенных пород. В дальнейшем подобный подход к автоматизации разметки лесных карт потенциально позволит увеличить интервал обновления данных в рамках полевых исследований и повысить их эффективность.

Ключевые слова: мониторинг леса, Природный парк Кумысная Поляна, машинное обучение, логистическая регрессия, метод опорных векторов, метод ближайших соседей, алгоритм случайный лес, XGBoost, CatBoost, LightGBM, сверточные нейронные сети, LSTM

Для цитирования: Огнева М. В., Шлапак П. А., Васильев А. А., Моисеев Д. С. Автоматическое определение лесных пород методами машинного обучения на основе обработки спутниковых снимков // Известия Саратовского университета. Новая серия. Серия: Науки о Земле. 2025. Т. 25, вып. 3. С. 194–200. <https://doi.org/10.18500/1819-7663-2025-25-3-194-200>, EDN: QMVWVB

Статья опубликована на условиях лицензии Creative Commons Attribution 4.0 International (CC-BY 4.0)

Article

Automatic identification of forest species using machine learning methods based on satellite image processing

М. В. Огнева, П. А. Шлапак[✉], А. А. Васильев, Д. С. Моисеев

Saratov State University, 83 Astrakhanskaya St., Saratov 410012, Russia

Marina V. Ogneva, mv_ogneva@mail.ru, <https://orcid.org/0000-0002-9828-7681>

Pavel A. Shlapak, henryxiv@list.ru, <https://orcid.org/0000-0002-6418-8749>

Alexander A. Vasilyev, guest838@yandex.ru, <https://orcid.org/0009-0005-2126-6427>

Denis S. Moiseev, dan.moiseeff2016@yandex.ru, <https://orcid.org/0009-0007-8383-5239>

Abstract. Monitoring of the condition and species diversity of tree species plays a significant role in the forest resource management. The emergence of high-quality multispectral satellite images opens up opportunities for using information about vegetation in a certain area over a long period of time extracted from images in addition to data obtained as a result of field research. The paper considers the use of satellite images from Sentinel 2 for automated classification using the example of the territory of the natural monument "Kumysnaya Polyana Nature Park" located in the vicinity of Saratov. Machine learning methods with a teacher were used as automation tools. The paper describes three approaches, differing in the algorithms used, as well as ways of structuring the information obtained from satellite images. As a result of the work, the test part of the study area was classified into seven types of trees, including regions dominated by the most common species. In the



future, a similar approach to automating the marking of forest maps will potentially increase the data update interval in field research and increase their effectiveness.

Keywords: forest monitoring, Kumysnaya Polyana Nature Park, machine learning, logistic regression, SVM, KNN, decision tree, algorithm random forest, XGBoost, CatBoost, LightGBM, CNN, LSTM

For citation: Ogneva M. V., Shlapak P. A., Vasilyev A. A., Moiseev D. S. Automatic identification of forest species using machine learning methods based on satellite image processing. *Izvestiya of Saratov University. Earth Sciences*, 2025, vol. 25, iss. 3, pp. 194–200 (in Russian). <https://doi.org/10.18500/1819-7663-2025-25-3-194-200>, EDN: QMVWVB

This is an open access article distributed under the terms of Creative Commons Attribution 4.0 International License (CC-BY 4.0)

Введение

Анализ состава древесных пород является неотъемлемой частью задачи мониторинга состояния лесных территорий. Данные о таком распределении позволяют получать информацию о влиянии различных биотических и абиотических факторов, таких как вырубки, засухи, пожары, на устойчивость лесной экосистемы, обновлять информацию об ареале охраняемых пород, актуализировать лесные карты прошлых лет, а также оценивать динамику изменения лесного состава. Основным источником информации для такого анализа являются полевые исследования. С повышением доступности и качества мультиспектральной спутниковой съемки стало возможным использование дополнительного источника информации в виде снимков древесно-кустарниковой растительности на некоторой территории в течение заданного промежутка времени в рамках анализа типов древесных пород. Тем не менее, разметка регионов по лесным породам на основании ранее описанных источников информации является трудоемкой задачей, требующей длительного времени работы специалиста. Автоматизация разметки лесных карт с использованием данных об эталонных участках, полученных в результате полевых исследований, является актуальной научно-практической задачей.

Цель работы – создать модель машинного обучения, способную автоматизировать процесс разметки территорий по лесным породам с помощью информации, получаемой со спутниковых снимков. Для достижения поставленной цели, были выполнены следующие задачи: 1) проанализировать состав пород исследуемой территории и выделить регионы с долей доминирующей древесной породы не менее 80%; 2) осуществить отбор подходов к обработке данных и автоматизации, способных обеспечить точность получаемой разметки не менее 0.95; 3) выполнить автоматизированную разметку эталонной регионов исследуемой территории и выявить участки, в рамках которых автоматизированная разметка выполняется с ошибкой.

В качестве объекта исследования была выбрана территория памятника природы «Природный парк Кумысная Поляна», расположенного в западной части г. Саратова, на Лысогорском плато и его склонах.

Предшествующие исследования

Использование математических методов обработки данных дистанционного зондирования в науках о Земле имеет весьма широкое распространение. Алгоритмы различной сложности и уровня используются в самых различных областях: в сельском хозяйстве [1–3], в исследованиях рельефа для различных задач [4–6], в мониторинге древесно-кустарниковых насаждений [7–10].

Существует достаточно большое количество работ российских и зарубежных авторов, рассматривавших задачу автоматизации идентификации древесных пород с помощью методов машинного обучения и данных со спутниковых снимков. Так, представляет интерес исследование [7], в котором авторами используется метод интерполяции дат для борьбы с облачностью и другими причинами возникновения некорректных значений в каналах получаемых изображений. На специально интерполированных наблюдениях, содержащих значения спектральных каналов, извлеченных из спутниковых снимков Sentinel-2, в работе проводится сравнительный анализ эффективности многослойного персептрона, сверточной нейронной сети, кодировщика на основе механизма внимания и алгоритма случайного леса в рамках задачи классификации лесов в центральной Франции.

Помимо этого проводилось исследование [8], связанное с использованием нейронных сетей для классификации изображений с целью определения доминирующих лесных пород в рамках территории Циньюаня. В данной работе оценивалось влияние используемой комбинации каналов на качество предсказаний модели, а также использовалось разделение изображения на географические локации размером 64×64 .

В исследовании [9] проводится сравнение моделей случайного леса и генеративного топографического картирования в рамках задачи идентификации тринадцати лесных пород на территории Раифского леса Волжско-Камского заповедника. Авторы предложили способ взвешенной оценки важности значений каналов при использовании группировки значений спутниковых снимков за сезон в зависимости от месяца съемки исходного изображения.

В работе [10] был представлен подход, связанный с использованием для классификации восьми древесных пород сегментационной модели Unet++ на множестве фрагментов 400×400

изображений спутниковых снимков Sentinel-2, для которых было осуществлено повышение разрешения с использованием дополнительных данных с других спутников.

Материалы и методы исследования

Основой для классификации леса на данной территории являлись мультиспектральные снимки со спутника Sentinel-2, полученные из открытых источников, сделанные с мая по сентябрь 2024 г. в различное время. Каждый из используемых снимков целиком покрывает исследуемую территорию. Помимо этого, использовалась разметка территории памятника природы «Природный парк Кумысная Поляна» по лесотаксационным выделам, выполненная в программном обеспечении QGIS, в которой содержались только регионы с долей доминирующей древесной породы не менее 80% (рис. 1).

В рамках работы всему выделу назначалась метка класса, соответствующая названию доми-

нирующей древесной породы. В исследовании участвовали выделы семи различных пород: ясень, дуб, береза, клен, сосна, липа и осина. В качестве алгоритмов для выполнения автоматизации разметки были выбраны методы машинного обучения с учителем. В рамках дальнейшей работы использовался язык программирования Python, а также дополнительные библиотеки, связанные с работой с данными в табличном формате, с реализацией алгоритмов обучения с учителем, с визуализацией данных. Всего в данной работе было апробировано три подхода. Для всех трех подходов производилось извлечение позиций пикселей, относящихся к каждому из классов древесных пород соответственно. Для этого исходный многоклассовый вектор с установленным составом древесной растительности на территории памятника природы «Природный парк Кумысная Поляна» был разделен на семь одноклассовых, которые затем накладывались на специально подготовленное изображение территории, сохраняющее исходные координаты снимка. Это выполнялось с целью на-

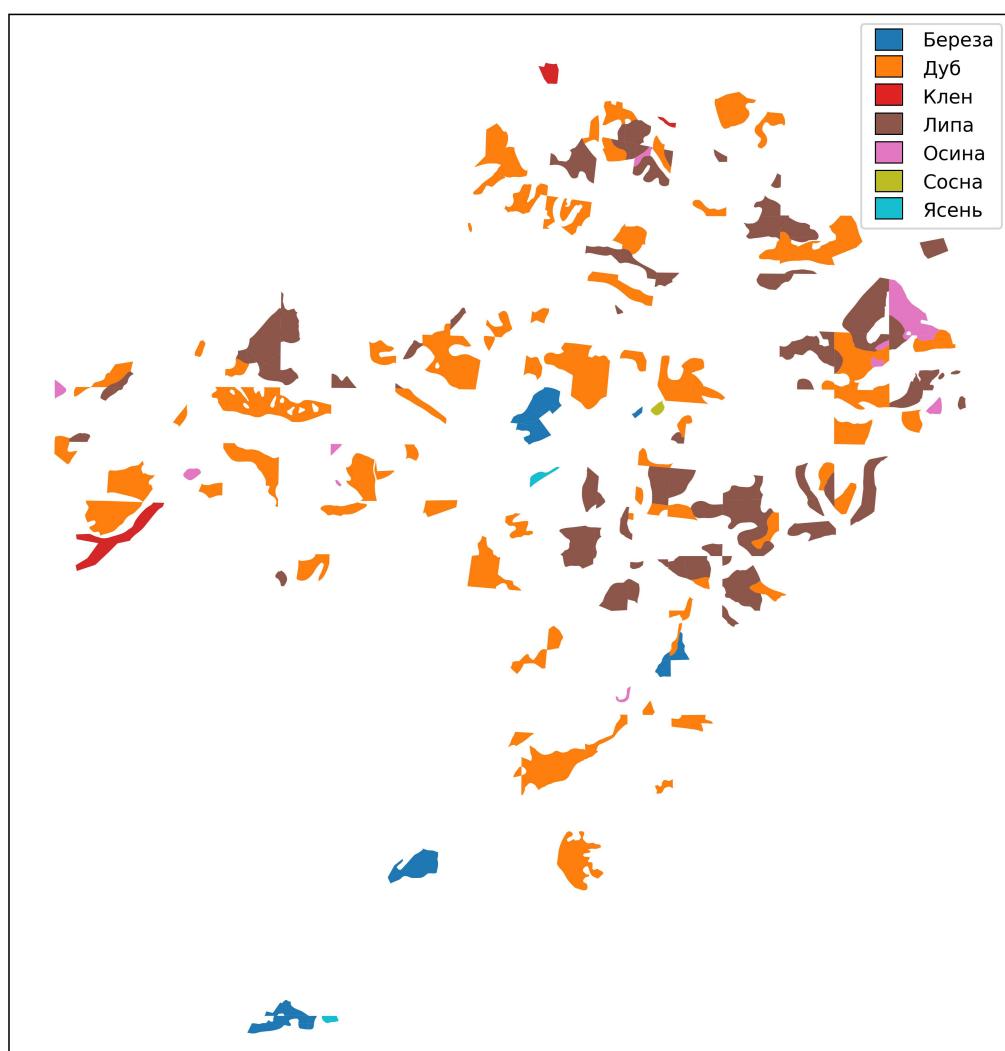


Рис. 1. Общая маска целевых областей древесных пород с цветовой индикацией принадлежности к классу (цвет онлайн)



локации вектора на растр с учетом географической позиции. Рассмотрим несколько подходов с разными концепциями обработки и структурирования данных.

1. Независимые пиксели. Для первого подхода каждый из полученных на предыдущем шаге пикселей считался новым объектом, признаками которого являлись значения в спектральных каналах. После описанной обработки данных был получен набор, включающий в себя 259790 образцов класса дуб, 163300 образцов класса липа, 24120 образцов класса береза, 14440 образцов класса осина, 10090 образца класса клен, 1610 образцов класса ясень, 730 образцов класса сосна. Перед обучением моделей было проведено разделение данных на тренировочную и тестовую выборки, а также стандартизация данных. С целью борьбы с несбалансированностью использовались веса для классов в моделях, пропорциональные количеству объектов в наборе данных. Использовались следующие модели машинного обучения: логистическая регрессия, метод ближайших соседей, дерево решений, случайный лес, а также градиентный бустинг в виде реализаций LightGBM и GradientBoostingClassifier.

2. Группировка разновременных пикселей по пространственному положению. Во втором подходе на основании того, что спутниковые снимки иллюстрируют определенную территорию в течение длительного периода времени, пиксели с одинаковым положением на различных изображениях были сгруппированы в один объект. Для полученного набора данных справедливы аналогичные пропорции распределения объектов по классам. Перед обучением моделей выполнялось разделение на тренировочную и тестовую выборку в соотношении 0.67 к 0.33 и стандартизация данных. Для нейронных сетей из тренировочного набора было дополнительно извлечено 10% данных в валидационную выборку с целью предотвращения переобучения моделей. Аналогично предыдущему подходу для моделей использовались веса классов с целью борьбы с несбалансированностью набора данных. В качестве алгоритмов машинного обучения использовались метод ближайших соседей (KNN), дерево решений (Decision Tree), алгоритм случайный лес (RF), логистическая регрессия (LogReg), градиентный бустинг в виде реализаций LightGBM, CatBoost, XGBoost, GradientBoostingClassifier, одномерные нейронные сети на основе полносвязных слоев (MLP), сверточной архитектуры (CNN), а также двунаправленных слоев с долгой краткосрочной памятью (LSTM).

3. Выделение окрестностей пикселей. В рамках третьего подхода использовался единственный снимок, сделанный в мае 2024 г. Для каждого пикселя, принадлежащего к одному из классов древесных пород, конструировалось изображение его окрестности размером 19×19 пикселей. Исходные двенадцать каналов получа-

емого изображения сжимались до одного с помощью анализа главных компонент (PCA). Затем полученный набор фотографий с метками классов был разделен на тренировочную и тестовую части. Количество объектов каждого класса в данном подходе полностью идентично предыдущему. В качестве модели использовалась сверточная нейронная сеть, состоящая из четырех блоков двумерной свертки и слоя агрегации с использованием функции максимума, после которых были добавлены еще один слой свертки, полносвязный слой из 30 нейронов и выходной слой.

Результаты и их обсуждение

Для наилучшей модели в рамках первого подхода были получены метрики accuracy – 0.88, а также макроусредненные метрики precision – 0.95, recall – 0.67 и F1-score – 0.77. Низкое качество классификации при использовании данного подхода может быть обусловлено отсутствием достаточного количества информации для эффективного прогнозирования древесной породы в двенадцати каналах одного пикселя вследствие сильного спектрального сходства определенных пород (таблица).

Качество моделей в рамках второго подхода на тестовой выборке

Модель	accuracy	precision	recall	F1-score
Ансамбль LightGBM, RF, XGBoost, CatBoost	0.99	0.99	0.96	0.98
XGBoost	0.99	0.99	0.96	0.97
LightGBM	0.99	0.99	0.96	0.97
CatBoost	0.97	0.96	0.97	0.96
RF	0.98	0.99	0.94	0.96
MLP	0.97	0.97	0.96	0.97
Decision Tree	0.96	0.94	0.90	0.92
Bidirectional LSTM	0.95	0.94	0.88	0.91
1D-CNN	0.95	0.96	0.81	0.87
GradientBoostingCLF	0.91	0.96	0.85	0.90
SVM	0.81	0.73	0.89	0.79
KNN	0.90	0.85	0.70	0.75
LogReg	0.66	0.44	0.83	0.52

Второй подход показал наилучшие результаты классификации, поэтому остановимся на нем более подробно. Для моделей данного подхода были получены аналогичные метрики.

Подход с группировкой пикселей во времени в рамках сезона позволил значительно улучшить общее качество классификации моделей за счет получения большего объема связанных между собой наблюдений для одного объекта. Модель логистической регрессии показала наихудшее качество среди всех моделей вследствие наличия выраженной зависимости в данных. Модели сверточной

нейронной сети и нейронной сети со слоями долгой краткосрочной памяти показали недостаточные для дальнейшего использования результаты, что может быть связано с наличием в наблюдениях блоков по двенадцать каналов, не являющихся

упорядоченными во времени. Лучше всего показали себя модели на основе деревьев решений и ансамблей. Оценивая маску ошибок наилучшей модели для всего исследуемого региона (рис. 2), можно сделать вывод, что большинство ошибок

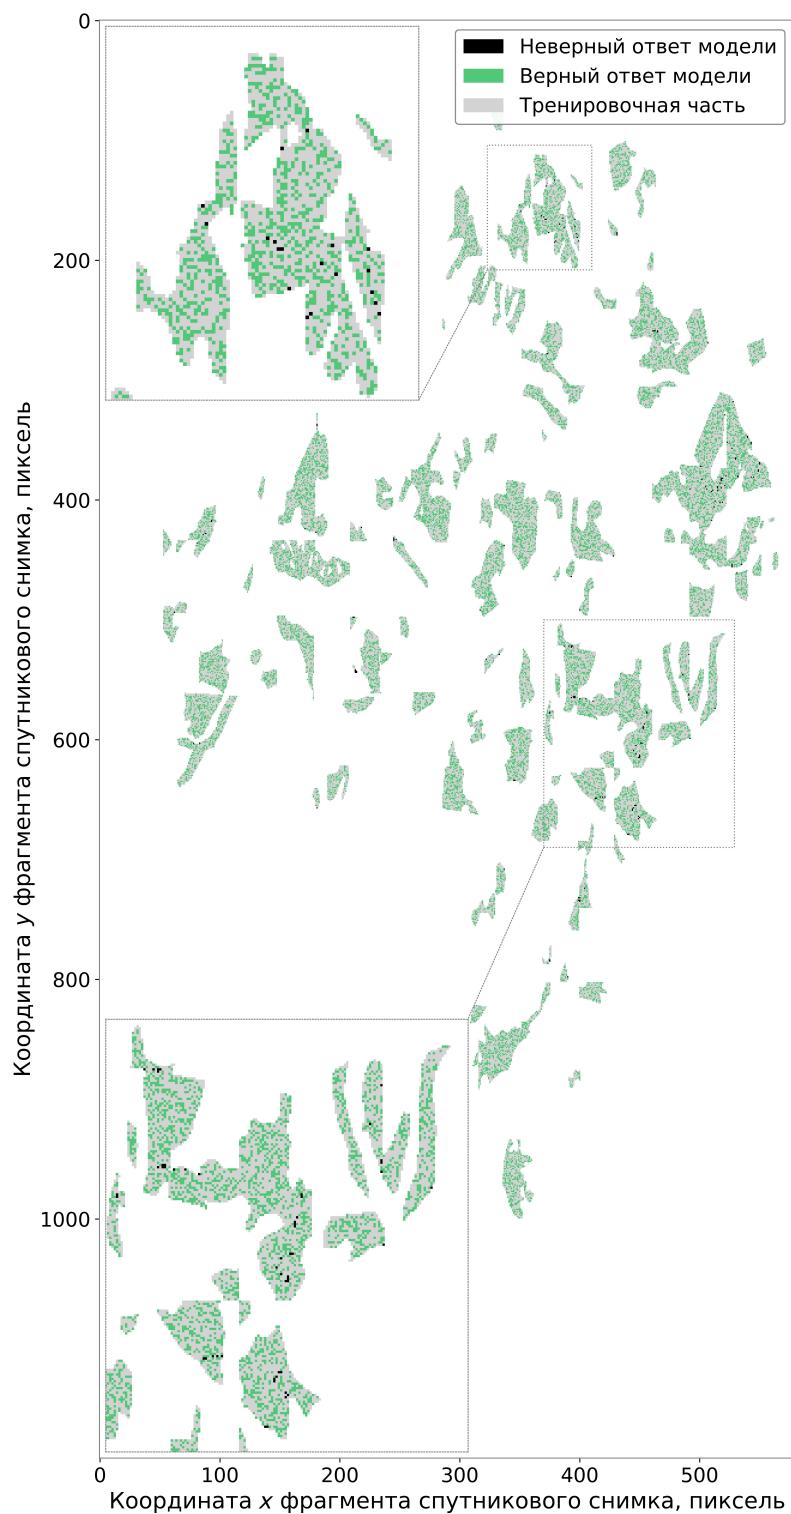


Рис. 2. Маска ошибок для ансамбля наилучших моделей в рамках подхода с группировкой разновременных пикселей по пространственному положению (цвет онлайн)



сосредоточены на границах пересечения выделов различных пород.

Так, например, смешивание осины в предсказаниях с лигой и дубом выражено в регионах с их близким расположением. Для большинства выделов, обособленных от используемых в разметке территорий других лесных пород, характерно смешивание с самым многочисленным классом – дубом.

На основании матрицы ошибок для результатов наилучшей модели (рис. 3) можно сделать вывод, что древесные породы, такие как ясень, клен и сосна, для которых в выборку попали регионы, не соседствующие с другими используемыми выделами, не попадают в предсказания для других классов.

Самый малочисленный класс ясения в рамках данной задачи модель чаще всего ошибочно идентифицируется с классами берески и дуба. Самое большое количество ошибок характерно для разделения самых многочисленных классов листвы и дуба, что скорее всего является следствием наличия множества смежных выделов соответствующих пород.

Описанные закономерности могут быть вызваны трудностями модели при прогнозировании древесной породы вследствие наличия погрешностей исходной разметки или ошибок самого алгоритма. Следует отметить, что для дальнейшего повышения качества работы моделей, необходимо использовать более точную разметку лесных

пород в рамках пикселя на основании полевых исследований, поскольку использование данных по выделам не позволяет локализовать участки местонахождения в данном регионе других пород.

Для третьего подхода были получены следующие результаты нейронной сети: accuracy – 0.95, макроусредненные значения recall – 0.95, precision – 0.96, F1-score – 0.95, что показывает достаточно высокое качество классификации модели, хоть и меньшее чем для предыдущего метода. Дальнейшее использование данного подхода представляет трудности из-за чрезмерного влияния соседствующих пикселей на результат работы алгоритма, что приведет к ухудшению работы модели для случаев смешанных лесов. Уменьшение размера используемого окна в рамках данного подхода значительно снижает общее качество работы модели и отрицательно влияет на осуществление точной разметки. Поэтому, несмотря на в целом неплохие результаты в рамках данного опыта, вызывает сомнение устойчивость и экстраполируемость алгоритмов, примененных в третьем подходе.

Заключение

Результаты исследования показали, что с помощью методов машинного обучения и данных дистанционного зондирования можно добиться достаточно высокой точности автоматизированной разметки пород древесной растительности



Рис. 3. Матрица ошибок для ансамбля наилучших моделей в рамках подхода с группировкой разновременных пикселей по пространственному положению (цвет онлайн)

на территории крупного лесного массива. Для дальнейшего определения устойчивости и экстраполируемости применяемых алгоритмов необходима оценка результатов использования их на других территориях.

Внедрение подобного подхода позволит оптимизировать процесс мониторинга территории лесов, а также повысить эффективность полевых исследований в данной области.

Авторам представляются следующие варианты практического применения результатов исследования.

1. Увеличение эффективности лесотаксационных мероприятий. Безусловно, даже абсолютно достоверная идентификация пород по космоснимкам не заменит полевой лесотаксации, которая включает в себя более подробное описание лесных сообществ. Но рекогносцировочные мероприятия при полевых работах или исследования в лесном хозяйстве на локальном или региональном уровне вполне могут быть осуществлены с помощью обработки данных дистанционного зондирования.

2. Выявление процессов, выступающих индикаторами глобальных изменений. Ярким примером является изменение состава растительных сообществ в результате динамики климатических процессов.

3. Определение участков, подверженных лесным пожарам, и участков выгоревшей древесно-кустарниковой растительности. Кроме того, автоматическая классификация пород может быть полезна в лесовосстановительной деятельности, в мониторинге процессов естественной или антропогенной сукцессии.

4. Мониторинг лесозаготовок и незаконных рубок древесной растительности.

5. Анализ и контроль надзорными органами лесных насаждений и лесополос

6. Мониторинг плодовых древесных и древесно-кустарниковых насаждений.

Таким образом, представленные в исследовании методы могут активно применяться в лесном хозяйстве и мониторинге геоэкологической ситуации, связанной с древесно-кустарниковыми насаждениями.

Библиографический список

1. Макаров В. З., Гусев В. А., Шлапак П. А., Решетарова Д. А. Выбор оптимального метода распознавания сельскохозяйственных культур по космоснимкам высокого разрешения (на примере саратовского Заволжья) // Известия Саратовского университета. Новая серия. Серия : Науки о Земле. 2020. Т. 20, вып. 3. С. 162–170. <https://doi.org/10.18500/1819-7663-2020-20-3-162-170>, EDN: EBJEPG
2. Ермолаев Н. Р., Юдин С. А., Белобров В. П., Ведедин Л. А., Шаповалов Д. А. Использование нейронных сетей и облачных сервисов для выделения геометрий сельскохозяйственных полей на основе данных дистанционного зондирования Земли // Исследования Земли из космоса. 2023. № 6. С. 98–105. <https://doi.org/10.31857/S0205961423060039>, EDN: ANJWSV
3. Аббасов И. Б., Дешмух Р. Р. Распознавание изображений сельскохозяйственных культур, растений и лесных массивов // Известия ЮФУ. Технические науки. 2020. № 3 (213). С. 202–212. <https://doi.org/10.18522/2311-3103-2020-3-202-212>, EDN: GLVQUZ
4. Данилов В. А., Морозова В. А., Мусеев Д. С. Применение математико-картографического моделирования для комплексной оценки оползневой опасности методом анализа иерархий на территории г. Саратова // Известия Саратовского университета. Новая серия. Серия : Науки о Земле. 2024. Т. 24, вып. 4. С. 259–268. <https://doi.org/10.18500/1819-7663-2024-24-4-259-268>, EDN: SEEUV
5. Данилов В. А., Морозова В. А., Фёдоров А. В., Шлапак П. А. Открытые данные дистанционного зондирования для выявления археологических объектов // Известия Саратовского университета. Новая серия. Серия : Науки о Земле. 2024. Т. 24, вып. 3. С. 150–158. <https://doi.org/10.18500/1819-7663-2024-24-3-150-158>, EDN: AQYZTX
6. Макаров В. З. Тюков Д. В., Шлапак П. А. Использование данных дистанционного зондирования Земли при изучении горных ледников (на примере ледника Алибек в Карачаево-Черкесии) // Известия Саратовского университета. Новая серия. Серия : Науки о Земле. 2022. Т. 22, вып. 1. С. 13–20. <https://doi.org/10.18500/1819-7663-2022-22-1-13-20>, EDN: IFZSKT
7. Mouret F., Morin D., Planells M., Vincent-Barbaroux C. Tree species classification at the pixel-level using deep learning and multispectral time series in an imbalanced context. URL: <https://arxiv.org/pdf/2408.08887.pdf> (дата обращения: 20.07.2025).
8. He T., Zhou H., Hu C., Hu J., Xue X., Xu L., Lou X., Zeng K., Wang Q. Deep Learning in Forest Tree Species Classification Using Sentinel-2 on Google Earth Engine: A Case Study of Qingyuan County // Sustainability. 2023. Vol. 15, iss. 3. Art. 2741. <https://doi.org/10.3390/su15032741>, EDN: JANRZL
9. Polyakova A., Mukharamova S., Yermolaev O., Shaykhutdinova G. Automated Recognition of Tree Species Composition of Forest Communities Using Sentinel-2 Satellite Data // Remote Sensing. 2023. Vol. 15, iss. 2. Art. 329. <https://doi.org/10.3390/rs15020329>, EDN: JHMBXQ
10. Bolyn C., Lejeune P., Michez A., Latte N. Mapping tree species proportions from satellite imagery using spectral-spatial deep learning // Remote Sensing of Environment. 2022. Vol. 280. Art. 113205 <https://doi.org/10.1016/j.rse.2022.113205>, EDN: NGROST

Поступила в редакцию 19.04.2025; одобрена после рецензирования 20.05.2025; принята к публикации 29.05.2025; опубликована 30.09.2025

The article was submitted 19.04.2025; approved after reviewing 20.05.2025; accepted for publication 29.05.2025; published 30.09.2025