

И.К. Говядин, А.Н. Чубинский

РАСПОЗНАВАНИЕ ДРЕВЕСНЫХ ПОРОД НА ОСНОВЕ АНАЛИЗА ИЗОБРАЖЕНИЙ

Введение. Алгоритмы компьютерного зрения позволяют анализировать морфологические особенности коры деревьев, их текстуру и цветковые характеристики, что делает возможным автоматическое определение породы на основе изображений [Miao et al., 2024]. В последние годы развитие глубокого обучения и сверточных нейронных сетей (англ. Convolutional Neural Networks, далее CNN) значительно повысило точность таких систем, сделав их применимыми в различных сферах, включая лесное хозяйство и экологический мониторинг [Войтов и др., 2023; Овсянников, 2024; Pradipkumar, Alagu Raja, 2022].

Беспилотные летательные аппараты (далее БПЛА) способны охватывать большие территории, проводить съемку в труднодоступных местах и обеспечивать получение изображений с высоким разрешением. Эти данные в сочетании с методами машинного обучения позволяют создавать надежные системы классификации древесных пород, способные работать в реальных условиях [Onishi, Ise, 2021]. При этом учитываются такие факторы, как вариативность освещения, ракурсов и сезонных изменений.

Традиционные методы идентификации древесных пород, основанные на визуальном анализе, морфологических измерениях и экспертной оценке специалистов-дендрологов, имеют ряд существенных ограничений. Они требуют значительных временных и финансовых затрат, а также подвержены субъективности оценки. Автоматизированные системы, использующие компьютерное зрение и машинное обучение, способны устранить эти недостатки, предоставляя быстрые и объективные результаты [Говядин, 2023; Каримов, Говядин, 2023; Carpentier et al., 2018].

Несмотря на значительный прогресс в области компьютерного зрения, применение таких технологий в лесном хозяйстве остается недостаточно изученным. Основные вызовы связаны с вариативностью внешнего вида коры различных деревьев, которая зависит от множества факторов, влияющих на формирование обучающей выборки. К таким факторам относятся возраст дерева, климатические условия, уровень влажности, наличие по-

вреждений и сезонные изменения. Кроме того, в естественных условиях кора может быть частично покрыта мхом, лишайниками или повреждена насекомыми, что значительно усложняет процесс классификации [Говядин и др., 2024; Kim et al., 2023].

Кора деревьев представляет собой сложную гетерогенную структуру, формирующуюся в процессе роста растения и выполняющую защитные функции. Ее морфологические особенности зависят от видовой принадлежности, возраста дерева, климатических условий и воздействия внешних факторов. Внешний слой коры, называемый перидермой, обеспечивает барьерную защиту и отличается высокой вариативностью фактуры. Внутренние слои, включая флоэму, участвуют в процессах обмена веществ и формирования вторичных структур.

Исследования структуры коры деревьев показали, что фактурные особенности являются одним из ключевых признаков, позволяющих идентифицировать породу [Kottilapurath Surendran et al., 2024]. Для хвойных пород характерны глубокие продольные борозды и чешуйчатые структуры, тогда как лиственные породы демонстрируют более разнообразную морфологию, включающую гладкие, трещиноватые или шелушащиеся поверхности. В рамках данного исследования использовался предварительно размеченный набор данных (dataset), содержащий изображения стволов семи древесных пород: березы, ели, сосны, осины, клена, дуба и лиственницы. Эти изображения включают разнообразные варианты текстуры и окраски, характерные для каждой породы, что позволяет учитывать природную изменчивость коры.

Существенным препятствием для автоматической классификации древесных пород является высокая изменчивость фактуры коры, обусловленная возрастом дерева. Молодые экземпляры часто характеризуются гладкой поверхностью коры, тогда как у взрослых деревьев кора становится грубой, растрескавшейся и покрытой вторичными структурами. Освещение и погодные условия также оказывают значительное влияние на визуальные характеристики коры, изменяя контрастность и цветовые параметры изображений, что может негативно сказываться на работе алгоритмов машинного обучения [Kim et al., 2022; Armi, Abbasi, 2023].

Дополнительную сложность представляет ракурс съемки, поскольку изображения, полученные с БПЛА, могут содержать значительные перспективные искажения. Изменение угла обзора влияет на восприятие фактуры, а тени, возникающие при съемке в густых лесных массивах, создают дополнительные артефакты. Сезонные изменения также вносят суще-

ственный вклад в вариативность данных, поскольку в разное время года кора может покрываться снегом, наледью или влагой, что изменяет ее оптические свойства.

Используемый в данном исследовании подход основан на методах глубокого обучения, в частности, на CNN, которые способны анализировать сложные паттерны фактуры и учитывать нелинейные зависимости между признаками. Предварительная обработка изображений включает нормализацию цветовых характеристик и применение методов выделения текстурных признаков, что позволяет минимизировать влияние внешних факторов, таких как освещение и погодные условия [Говядин и др., 2023].

Целью данного исследования является разработка и внедрение метода автоматического распознавания древесных пород на основе анализа изображений стволов. Работа направлена на повышение точности и эффективности классификации древесных пород за счет применения современных алгоритмов машинного обучения, а также на оценку применимости предложенного подхода в реальных условиях лесного хозяйства.

Материалы и методика исследования. Методология исследования включает следующие этапы: сбор и предобработка данных, выбор архитектуры модели, обучение и валидация, а также оценка результатов и их интерпретация.

Сбор данных осуществлялся с использованием БПЛА, что позволило получать изображения стволов деревьев в вертикальной плоскости, включая труднодоступные верхние части ствола, которые невозможно зафиксировать с помощью мобильных устройств, таких как смартфоны.

Набор данных включает изображения с различными параметрами съемки, такими как угол обзора (например, под прямым углом к стволу, с наклоном сверху или снизу), расстояние до объекта (крупный план или дальний план) и интенсивность освещения (включая как освещенные участки, так и затененные области). Это обеспечивает высокую вариативность входных данных, что важно для повышения устойчивости модели к различным условиям съемки. Для улучшения качества классификации данные были разделены на обучающую, валидационную и тестовую выборки в пропорции 70:20:10.

Дополнительно проводилась оценка качества исходных изображений, включая проверку разрешения (определялось, обладают ли изображения достаточной четкостью и детализацией для распознавания текстуры и морфологических особенностей коры деревьев), контрастности (оценива-

лась степень различимости текстурных особенностей коры, таких как линии, трещины и пятна) и наличия артефактов, таких как тени и блики.

С целью увеличения объема набора данных применялись методы аугментации данных, включая поворот, масштабирование, изменение яркости и добавление шумов (мелкие искажения). Эти методы позволили искусственно создать новые варианты изображений на основе имеющихся данных, что способствовало улучшению генерализации модели и снижению вероятности переобучения.

Рассмотрены и протестированы различные архитектуры CNN, включая ResNet, EfficientNet и MobileNet, с целью выявления оптимального компромисса между точностью классификации и вычислительной сложностью модели. В настоящее время окончательный выбор архитектуры еще не сделан, так как исследование находится на стадии анализа и доработки. Тем не менее, для продолжения работы выбран промежуточный вариант модели, который позволяет проводить исследования и тестирование методик предобработки данных, настройки гиперпараметров и аугментации. Такой подход обеспечивает гибкость в исследовании и позволяет оптимизировать модель по мере получения новых результатов.

Обучение модели проводилось с использованием метода обучения с учителем. В качестве входных данных использовались изображения стволов деревьев, предварительно обработанные и размеченные в соответствии с их породой.

Для инициализации весов модели применялись предварительно обученные параметры (такая модель уже «знает» общие признаки изображений, такие как линии, текстуры и формы), после чего выполнялось дополнительное обучение на специализированном наборе данных. В качестве функции потерь использовалась кросс-энтропия (математическая функция, измеряющая разницу между предсказаниями модели и реальными метками), а в качестве оптимизатора – алгоритм Adam (метод адаптивной оптимизации, который обновляет веса модели в процессе обучения). Этот подход обеспечил эффективную сходимость за счет адаптивного изменения коэффициентов обучения.

Обучение модели проводилось в несколько этапов, что позволило улучшить адаптацию модели к данным и снизить вероятность ошибок. На первом этапе использовались небольшие мини-пакеты данных (по 32 изображения за раз), что способствовало повышению устойчивости модели к переобучению. На втором этапе применялась регуляризация (набор методов, направленных на улучшение способности модели к обобщению дан-

ных), включая технику «dropout» (обнуление нейронов в слое модели во время обучения с вероятностью 0,4, то есть 40% нейронов) и «batch normalization» для нормализации данных и предотвращения переобучения.

Дополнительно были проведены эксперименты с различными значениями гиперпараметров, включая размер мини-пакетов, коэффициент обучения и количество эпох, с целью оптимизации модели. Оценка качества модели осуществлялась на валидационной выборке, а итоговые показатели метрик, таких как точность (доля правильных предсказаний), полнота (если цель – определить класс «Берёза», то полнота показывает, какой процент всех «Берёз» в наборе данных был правильно идентифицирован) и F1-score (среднее гармоническое между точностью и полнотой), анализировались после завершения обучения.

Также была проведена сегментация изображений с целью выделения области интереса – ствола дерева – и удаления фоновых объектов, таких как листья и ветви. Для этого использовались алгоритмы пороговой сегментации (например, все пиксели, яркость которых превышает заданный порог, классифицируются как «фон», а остальные – как «область интереса») и модели глубокого обучения для семантической сегментации (пиксели, принадлежащие стволу дерева, классифицируются как «ствол», а остальные – как «не ствол»).

Для повышения устойчивости модели к вариациям условий съемки применялись методы цветовой коррекции, позволяющие компенсировать изменения освещения и цветопередачи. Это делает модель более универсальной и надежной для использования в реальных условиях, таких как лесные массивы при различных погодных условиях и в разное время суток.

Результаты исследования. В ходе исследования проведена оценка точности работы предложенной модели классификации древесных пород (рис. 1). Обученная свёрточная нейронная сеть продемонстрировала высокую эффективность, достигая средней точности более 90% на тестовом наборе данных.

Наилучшие показатели были достигнуты для пород с выраженной фактурой коры, таких как дуб и береза, где точность классификации превышала 95%. В то же время для пород, имеющих схожие фактурные характеристики, таких как ель и сосна, точность оказалась несколько ниже (около 85%), что обусловлено близостью их визуальных признаков.

Ниже представлены сводные результаты тестирования модели классификации древесных пород (табл. 1).



Рис. 1. Пример фотоматериалов набора данных
Fig. 1. Sample photographic dataset

Точность модели, отражающая долю корректно классифицированных изображений, оказалась максимальной для дуба (97,6%) и берёзы (95,4%). Это объясняется выраженностью текстурных особенностей их коры, что упрощает процесс идентификации. Наименьшая точность зафиксирована для ели (86,7%) и сосны (85,2%), что связано с высокой степенью схожести их текстурных характеристик, создающей дополнительные сложности для классификации.

Таблица 1

Анализ ключевых характеристик

Analysis of key characteristics

№ п/п	Порода	Точность (%)	Полнота (%)	F1-score (%)	Среднее время классификации (миллисекунд)
1	Берёза	95,4	94,1	94,7	12
2	Ель	86,7	85,9	86,3	15
3	Сосна	85,2	84,0	84,6	14
4	Осина	92,1	91,0	91,5	13
5	Клён	90,3	89,7	90,0	12
6	Дуб	97,6	96,8	97,2	16
7	Лиственница	88,9	87,5	88,2	14

Показатель полноты демонстрирует, какой процент объектов определённого класса модель смогла корректно идентифицировать. Для дуба и берёзы полнота оказалась на высоком уровне, что подтверждает надёжность модели в распознавании этих пород. F1-score, отражающий баланс между точностью и полнотой, в среднем превышает 90% для большинства пород. Однако для схожих пород, таких как ель и сосна, F1-score снижается до 84–86%, что указывает на необходимость доработки модели для улучшения классификации этих пород.

Среднее время классификации изменяется в диапазоне от 12 до 16 миллисекунд. Наименьшее время обработки наблюдается для изображений берёзы и клёна, что связано с их относительно простыми текстурными особенностями. Наибольшее время классификации требуется для дуба, поскольку его кора обладает сложной фактурой, требующей более детального анализа.

В целом модель показала высокую эффективность при классификации древесных пород, достигая средней точности более 90%. Однако для пород с визуально схожими характеристиками требуется дополнительная работа. Это может включать улучшение качества исходного набора данных или применение более сложных архитектур модели для повышения точности классификации.

На графиках (рис. 2) представлены результаты анализа производительности модели классификации древесных пород с использованием ROC-кривых и Precision-Recall кривых.




Рис. 2. Производительность модели

Fig. 2. Model performance

ROC-кривые демонстрируют способность модели дифференцировать истинные и ложные классы для каждой из исследуемых древесных пород. Высокое значение площади под кривой (AUC) указывает на хорошую работу модели. Например, для пород с ярко выраженными текстурными особенностями (например, дуба и берёзы) AUC стремится к 1, что подтверждает высокую точность классификации. Напротив, для схожих пород, таких как ель и сосна, наблюдаются несколько менее выраженные результаты, что связано с близостью их текстурных признаков.

Precision-Recall кривые иллюстрируют баланс между точностью (доля правильных предсказаний среди всех, определённых моделью как данный класс) и полнотой (доля правильно предсказанных объектов среди всех объектов этого класса). Этот график особенно полезен для оценки работы модели при наличии несбалансированных данных. Наибольший баланс между точностью и полнотой наблюдается для дуба и берёзы, что подтверждает высокую эффективность модели при классификации этих пород.

На графике (рис. 3) представлена зависимость метрики F1-score от коэффициента обучения модели.

Анализ графика демонстрирует, что при чрезмерно низких значениях коэффициента обучения (например, 0,0001) скорость сходимости модели существенно снижается, что приводит к недостаточной оптимизации и низкому значению F1-score (78,2%). Наилучшие результаты достигаются при коэффициенте обучения 0,01, где модель демонстрирует максимальное значение F1-score (91,3%), что свидетельствует о балансе между скоростью обучения и качеством классификации. Однако при дальнейшем увеличении коэффициента обучения (например, выше 0,01) наблюдается снижение качества классификации, что связано с нестабильностью процесса оптимизации: модель либо переобучается, либо теряет способность к сходимости.




Рис. 3. Зависимость метрики

Fig. 3. Metric dependency

Уравнение полиномиальной регрессии второй степени, описывающее зависимость F1-score от коэффициента обучения, наглядно демонстрирует, как изменяется F1-score при различных значениях коэффициента обучения. Кривая аппроксимации отражает общую тенденцию: увеличение коэффициента обучения сначала приводит к улучшению F1-score, однако после достижения определённого значения (0,01) качество модели начинает снижаться.

Степень сложности и разнообразия фактуры коры, которая различна у разных пород деревьев, является ключевым фактором, влияющим на работу модели классификации. Фактура коры определяет уникальные признаки, по которым модель распознаёт породу (рис. 4).

Результаты регрессионного анализа показывают, что основными факторами, влияющими на точность классификации, являются угол съёмки и уровень освещённости. Точность снижается с увеличением угла съёмки, что связано с перспективными искажениями фактуры. Освещённость также играет значительную роль: низкий уровень освещения способствует повышению точности модели, так как тени и яркие блики минимизируются, тогда как высокая освещённость приводит к менее стабильным результатам. Влияние фактурной изменчивости на точность оказалось минимальным, что свидетельствует о способности модели эффективно справляться как с простой, так и со сложной фактурой коры. Однако низкое значение коэффициента детерминации ($R^2 = 0,243$) указывает на необходимость учёта дополнительных факторов для полного объяснения вариации точности.




Рис. 4. Зависимость точности от текстурной изменчивости и освещенности
 Fig. 4. Accuracy dependence on texture variability and illumination

Для фактур с высокой изменчивостью точность классификации в среднем ниже, особенно при низкой освещённости. В то же время низкая текстурная изменчивость обеспечивает более стабильные результаты, что подтверждается меньшим разбросом значений точности.

Заключение. Результаты исследования показывают, что разработанная модель классификации древесных пород демонстрирует высокую эффективность, достигая средней точности более 90% на тестовом наборе данных. Наиболее успешные результаты были получены для пород с ярко выраженной фактурой коры, таких как дуб и берёза, где точность превышает 95%. Это свидетельствует о способности модели эффективно извлекать ключевые признаки из изображений с выраженными фактурными элементами.

Тем не менее, модель сталкивается с трудностями при классификации пород с визуально схожей фактурой, таких как ель и сосна. Точность для этих пород составила около 85%, что указывает на недостаточную дифференцирующую способность модели для подобных классов. Это может быть связано как с ограничениями используемого набора данных, так и с архитектурными особенностями модели. Для улучшения классификации таких пород рекомендуется рассмотреть возможность увеличения объёма данных для этих классов и добавления дополнительных признаков, таких как спектральные характеристики или морфометрические параметры.

Анализ влияния внешних факторов выявил, что угол съёмки и уровень освещённости существенно влияют на точность классификации. С увеличением угла съёмки точность снижается, что связано с перспективными искажениями фактуры. Освещённость также оказалась значимым фактором: при низком уровне освещения точность повышается за счёт уменьшения артефактов, таких как блики, тогда как при высоком уровне освещённости наблюдаются менее стабильные результаты. Эти выводы подчёркивают необходимость дальнейшей работы с аугментацией данных, включая моделирование различных углов съёмки и условий освещённости.

Примечательно, что фактурная изменчивость, вопреки ожиданиям, оказывает статистически незначимое влияние на точность классификации. Это может свидетельствовать о высокой адаптивности модели, способной эффективно обрабатывать как однородные, так и гетерогенные текстуры. Однако низкий коэффициент детерминации регрессионной модели ($R^2 = 0,243$) указывает на ограниченную объяснительную способность текущего набора предикторов. Для более полного объяснения вариации точности целесообразно включение дополнительных факторов, таких как влажность коры, наличие биологических повреждений (например, следов насекомых или грибковых поражений), а также учет сезонных изменений морфологических характеристик древесных стволов.

В целом предложенный подход подтвердил свою применимость для автоматической классификации древесных пород на основе анализа изображений стволов деревьев, полученных с использованием БПЛА. Однако рекомендуется расширить обучающую выборку, включить дополнительные параметры окружающей среды и провести кросс-валидацию на независимых наборах данных.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Библиографический список

Войтов Д.Ю., Васильев С.Б., Кормилицын Д.В. Разработка технологии определения породы деревьев с применением компьютерного зрения // Лесной вестник. 2023. Т. 27, № 1. С. 60–66. DOI: 10.18698/2542-1468-2023-1-60-66.

Говядин И.К. Инновационные подходы к сбору данных о высотах и диаметрах деревьев в насаждениях // Перспективы развития лесного комплекса: сб. науч. тр. межд. науч.-практ. конф. Брянск, 2023. С. 179–182.

Говядин И.К., Чубинский А.Н., Алексеев А.С. Метод измерения диаметров деревьев на основе технологий искусственного интеллекта // Известия Санкт-Петербургской лесотехнической академии. 2024. Вып. 249. С. 177–194. DOI: 10.21266/2079-4304.2024.249.177-194.

Говядин И.К., Каримов Б.М., Шеремет В.А. Система визуализации данных. Свидетельство о государственной регистрации программы для ЭВМ № 2023612089 Российская Федерация: № 2022668020; заявл. 30.09.2022; опубл. 30.01.2023.

Каримов Б.М., Говядин И.К. Искусственный интеллект в лесной отрасли: возможности и перспективы // Современные тренды управления и цифровая экономика: от регионального развития к глобальному экономическому росту: сб. ст. V Межд. науч.-практ. конф. Екатеринбург, 2023. С. 334–338.

Овсянников А.В. Методология классификации пород деревьев бореальных лесов с использованием архитектуры Efficientnet искусственного интеллекта // Journal of Agriculture and Environment. 2024. No. 5 (45). DOI: 10.60797/JAE.2024.45.8.

Armi L., Abbasi E. Tree Bark Classification using Color-improved Local Quinary Pattern and Stacked MEETG // Journal of Artificial Intelligence and Data Mining (JAIDM). 2023. Vol. 11, no. 3. P. 391–405. DOI: 10.22044/jadm.2023.12692.2420.

Carpentier M., Giguère P., Gaudreault J. Tree Species Identification from Bark Images Using Convolutional Neural Networks // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). 2018. DOI: 10.48550/arXiv.1803.00949.

Kim T.K., Hong J., Ryu D., Kim S., Byeon S.Y., Huh W., Kim K., Baek G.H., Kim H.S. Identifying and extracting bark key features of 42 tree species using convolutional neural networks and class activation mapping // Scientific Reports. 2022. Vol. 12. Art. no. 4772. DOI: 10.1038/s41598-022-08571-9.

Kim J.-H., Purusatama B.D., Savero A., Prasetya D., Jang J., Park S.-Y., Lee S., Kim N. Convolutional neural network performance and the factors affecting performance for classification of seven *Quercus* species using sclereid characteristics in the bark // BioResources. 2023. Vol. 19. P. 510–524. DOI: 10.15376/biores.19.1.510-524.

Kottilapurath Surendran G., Deekshitha, Lukac M., Výboštok J., Mokros M. A forestry investigation: Exploring factors behind improved tree species classification using bark images // Ecological Informatics. 2024. Vol. 85, iss. 1. Art. no. 102932. DOI: 102932. 10.1016/j.ecoinf.2024.102932.

Miao S., Zhang K., Zeng H., Liu J. AI-Based Tree Species Classification Using Pseudo Tree Crown Derived From UAV Imagery (preprint). 2024. DOI: 10.20944/preprints202402.0786.v1.

Onishi M., Ise T. Explainable identification and mapping of trees using UAV RGB image and deep learning // Scientific Reports. 2021. Vol. 11. Art. no. 903. DOI: 10.1038/s41598-020-79653-9.

Pradipkumar V.H., Alagu Raja R.A. Automatic Identification of Tree Species from UAV Images Using Machine Learning Approaches // Journal of the Indian Society of Remote Sensing. 2022. Vol. 50. P. 2447–2464. DOI: 10.1007/s12524-022-01608-6.

References

Armi L., Abbasi E. Tree Bark Classification using Color-improved Local Quinary Pattern and Stacked MEETG. *Journal of Artificial Intelligence and Data Mining (JAIDM)*, 2023, vol. 11, no. 3, pp. 391–405. DOI: 10.22044/jadm.2023.12692.2420.

Carpentier M., Giguère P., Gaudreault J. Tree Species Identification from Bark Images Using Convolutional Neural Networks. *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2018. DOI: 10.48550/arXiv.1803.00949.

Govyadin I.K. Innovative approaches to collecting data on the heights and diameters of trees in plantations. *Prospects for the development of the forestry complex: collection of scientific papers of the int. sci.-pract. conf.* Bryansk, 2023, pp. 179–182. (In Russ.)

Govyadin I.K., Karimov B.M., Sheremet V.A. Data visualization system. Certificate of state registration of a computer program No. 2023612089 Russian Federation: No. 2022668020; decl. 09/30/2022; publ. 01/30/2023. (In Russ.)

Govyadin I.K., Chubinsky A.N., Alekseev A.S. Method for measuring tree diameters based on artificial intelligence technologies. *Izvestia Sankt-Peterburgskoj Lesotekhniceskoj Akademii*, 2024, iss. 249, pp. 177–194. DOI: 10.21266/2079-4304.2024.249.177-194. (In Russ.)

Karimov B.M., Govyadin I.K. Artificial intelligence in the forestry industry: opportunities and prospects // *Modern management trends and digital economy: from regional development to global economic growth: collection of articles from the V Int. sci.-pract. conf.* Ekaterinburg, 2023, pp. 334–338.

Kim T.K., Hong J., Ryu D., Kim S., Byeon S.Y., Huh W., Kim K., Baek G.H., Kim H.S. Identifying and extracting bark key features of 42 tree species using convolutional neural networks and class activation mapping. *Scientific Reports*, 2022, vol. 12, art. no. 4772. DOI: 10.1038/s41598-022-08571-9.

Kim J.-H., Purusatama B.D., Savero A., Praselia D., Jang J., Park S.-Y., Lee S., Kim N. Convolutional neural network performance and the factors affecting performance for classification of seven *Quercus* species using sclereid characteristics in the bark. *BioResources*, 2023, vol. 19, pp. 510–524. DOI: 10.15376/biores.19.1.510-524.

Kottilapurath Surendran G., Deekshitha, Lukac M., Výboštok J., Mokros M. A forestry investigation: Exploring factors behind improved tree species classification using bark images. *Ecological Informatics*, 2024, vol. 85, iss. 1, art. no. 102932. DOI: 10.1016/j.ecoinf.2024.102932.

Miao S., Zhang K., Zeng H., Liu J. AI-Based Tree Species Classification Using Pseudo Tree Crown Derived From UAV Imagery (preprint). 2024. DOI: 10.20944/preprints202402.0786.v1.

Onishi M., Ise T. Explainable identification and mapping of trees using UAV RGB image and deep learning. *Scientific Reports*, 2021, vol. 11, art. no. 903. DOI: 10.1038/s41598-020-79653-9.

Ovsyannikov A.V. Methodology for classification of boreal forest tree species using the Efficientnet artificial intelligence architecture. *Journal of Agriculture and Environment*, 2024, no. 5 (45). DOI: 10.60797/JAE.2024.45.8. (In Russ.)

Pradipkumar V.H., Alagu Raja R.A. Automatic Identification of Tree Species from UAV Images Using Machine Learning Approaches. *Journal of the Indian Society of Remote Sensing*, 2022, vol. 50, pp. 2447–2464. DOI: 10.1007/s12524-022-01608-6.

Voitov D.Yu., Vasilyev S.B., Kormilitsyn D.V. Development of technology for determining tree species using computer vision. *Forestry Bulletin*, 2023, vol. 27, no. 1, pp. 60–66. DOI: 10.18698/2542-1468-2023-1-60-66. (In Russ.)

Материал поступил в редакцию 05.02.2025

Говядин И.К., Чубинский А.Н. Распознавание древесных пород на основе анализа изображений // Известия Санкт-Петербургской лесотехнической академии. 2025. Вып. 255. С. 262–276. DOI: 10.21266/2079-4304.2025.255.262-276

В статье представлен метод автоматического распознавания древесных пород на основе анализа изображений стволов деревьев, полученных с использованием беспилотных летательных аппаратов (БПЛА). Авторы применяют сверточные нейронные сети (CNN) для классификации семи древесных пород: берёзы, ели, сосны, осины, клёна, дуба и лиственницы. Исследование направлено на преодоление ограничений традиционных методов идентификации, таких как субъективность экспертной оценки и высокая трудоёмкость. Методология включает сбор и предварительную обработку данных, аугментацию изображений для увеличения вариативности, а также обучение модели с использованием архитектур ResNet, EfficientNet и MobileNet. Результаты демонстрируют высокую эффективность модели: средняя точность классификации превышает 90%, при этом наилучшие показатели достигнуты для дуба (97,6%) и берёзы (95,4%). Для пород с визуально схожей фактурой (ель и сосна) точность составила около 85%, что указывает на необходимость дальнейшей оптимизации. Анализ влияния внешних факторов выявил значимость угла съёмки и уровня освещённости для точности классификации. Предложенный метод может быть использован в лесном хозяйстве для автоматизации мониторинга и управления ресурсами. Для повышения эффективности авторы рекомендуют расширить набор данных, включить дополнительные параметры окружающей среды и провести кросс-валидацию на независимых выборках.

Ключевые слова: искусственный интеллект, компьютерное зрение, машинное обучение, анализ деревьев, распознавание деревьев, алгоритмы ИИ.

Govyadin I.K., Chubinsky A.N. Recognition of tree species based on image analysis. *Izvestia Sankt-Peterburgskoj Lesotekhniceskoj Akademii*, 2025, iss. 255, pp. 262–276 (in Russian with English summary). DOI: 10.21266/2079-4304.2025.255.262-276

The article presents a method for the automatic recognition of tree species based on the analysis of tree trunk images captured using unmanned aerial vehicles (UAVs). The authors employ convolutional neural networks (CNNs) to classify seven tree species: birch, spruce, pine, aspen, maple, oak, and larch. The study aims to overcome the limitations of traditional identification methods, such as subjective expert assessment and high labor intensity. The methodology includes data collection and preprocessing, image augmentation to increase variability, and model training using ResNet, EfficientNet, and MobileNet architectures. The results demonstrate the model's high efficiency, with an average classification accuracy exceeding 90%. The best performance was achieved for oak (97,6%) and birch (95,4%), while visually similar species (spruce and pine) showed lower accuracy (around 85%), indicating the need for further optimization. An analysis of external factors revealed the significant impact of shooting angle and lighting conditions on classification accuracy. The proposed method can be applied in forestry for automated monitoring and resource management. To enhance performance, the authors recommend expanding the dataset, incorporating additional environmental parameters, and conducting cross-validation on independent datasets.

Keywords: artificial intelligence, computer vision, machine learning, tree analysis, tree recognition, AI algorithms.

ГОВЯДИН Илья Константинович – доцент кафедры технологии материалов, конструкций и сооружений из древесины Санкт-Петербургского государственного лесотехнического университета имени С.М. Кирова, кандидат технических наук. Researcher ID: AAF-5782-2019. ORCID: 0000-0002-0143-1916.

194021, Институтский пер., д. 5, лит. У, Санкт-Петербург, Россия. E-mail: govadin812@gmail.com

GOVYADIN Ilya K. – PhD (Technical), St.Petersburg State Forest Technical University. Researcher ID: AAF-5782-2019. ORCID: 0000-0002-0143-1916.

194021. Institute per. 5. Let. U. St. Petersburg. Russia. E-mail: govadin812@gmail.com

ЧУБИНСКИЙ Анатолий Николаевич – профессор кафедры технологии материалов, конструкций и сооружений из древесины Санкт-Петербургского государственного лесотехнического университета имени С.М. Кирова, доктор технических наук. Researcher ID: I-9432-2016. ORCID: 0000-0001-7914-8056.

194021, Институтский пер., д. 5, лит. У, Санкт-Петербург, Россия. E-mail: a.n.chubinsky@gmail.com

CHUBINSKY Anatoly N. – DSc (Technical), Professor, St.Petersburg State Forest Technical University. Researcher ID: I-9432-2016. ORCID: 0000-0001-7914-8056.

194021. Institute per. 5. Let. U. St. Petersburg. Russia. E-mail: a.n.chubinsky@gmail.com