

*Р.Д. Шагалиев, Е.А. Богдан✉, А.Ф. Галямов, Л.Н. Белан,
О.И. Ишкинина, Г.Г. Валиев*

Уфимский государственный нефтяной технический университет, г. Уфа, Россия

✉ eavolkova@bk.ru

ИДЕНТИФИКАЦИЯ СУХОСТОЙНЫХ ДЕРЕВЬЕВ С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ОСНОВЕ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

Аннотация. На территории Российской Федерации отмечаются массовые усыхания древостоя, которые вызваны воздействием патогенных организмов, насекомых, грибных инвазий, а также распространением бактериальных заболеваний деревьев. Разработка систем дистанционного мониторинга лесных экосистем крайне важна для управления лесными ресурсами и принятия обоснованных решений в отношении сохранения и восстановления лесов. Целью настоящего исследования является разработка программного модуля для автоматизации процесса идентификации сухостойных деревьев на основе данных дистанционного зондирования Земли. Анализ различных стратегий обнаружения и сегментации, включая традиционные методы компьютерного зрения и нейронные сети на основе искусственного интеллекта, позволил выбрать обнаружение объектов в качестве основного метода из-за его эффективности при маркировке и способности количественно оценивать участки поражения деревьев. Сочетание метода обнаружения объектов со снимками высокого разрешения, полученными с применением БПЛА, оказалось наиболее эффективным для точного обнаружения сухостойных деревьев.

Ключевые слова: искусственный интеллект, изменение климата, дистанционное зондирование Земли, беспилотные летательные аппараты, спутниковые снимки, обнаружение объектов, сегментация.

Для цитирования: Шагалиев Р.Д., Богдан Е.А., Галямов А.Ф., Белан Л.Н., Ишкинина О.И., Валиев Г.Г. Идентификация сухостойных деревьев с помощью искусственного интеллекта на основе данных дистанционного зондирования Земли. *Вестник СВФУ. Серия «Науки о Земле»*. 2024, № 4. С. 138–149. DOI: 10.25587/2587-8751-2024-4-138-149

Финансирование: исследование выполнено в рамках программы Министерства науки и высшего образования Российской Федерации «Приоритет-2030» (Национальный проект «Наука и университеты»).

*R.D. Shagaliev, E.A. Bogdan✉, A.F. Galyamov, L.N. Belan,
O.I. Ishkinina, G.G. Valiev*

Ufa State Petroleum Technological University, Ufa, Russia

✉ eavolkova@bk.ru

IDENTIFICATION OF DEAD TREES USING ARTIFICIAL INTELLIGENCE BASED ON EARTH REMOTE SENSING DATA

Abstract. On the territory of the Russian Federation, there are massive shrinking of the stand, which are caused by the effects of pathogens, insects, fungal infestations, as well as the spread of bacterial diseases of trees. The development of remote monitoring systems for forest ecosystems is extremely important for the management of forest resources and making informed decisions regarding the conservation and restoration of forests. The purpose of this study was the development of a software module for automating the identification process of dead trees based on Earth remote sensing data. The analysis of various detection and segmentation strategies, including traditional computer vision methods and neural networks based on artificial intelligence, made it possible to choose object detection as the main method due to its effectiveness in labeling and the ability to quantify areas of tree damage. The combination of the object detection method with high-resolution images obtained using UAVs proved to be the most effective for accurate detection of dead trees.

Keywords: artificial intelligence, climate change, remote sensing of the Earth, unmanned aerial vehicles, satellite imagery, object detection, segmentation.

For citation: Shagaliev R.D., Bogdan E.A., Galyamov A.F., Belan L.N., Ishkinina O.I., Valiev G.G. Identification of dead trees using artificial intelligence based on Earth remote sensing data. *Vestnik of NEFU. Earth Sciences*. 2024, № 4. Pp. 138–149. DOI: 10.25587/2587-8751-2024-4-138-149

Funding: the research was carried out within the framework of the program of the Ministry of Science and Higher Education of the Russian Federation “Priority 2030” (National project “Science and Universities”).

Введение

Территория России на 46,4 % занята лесами [1], что определяет глобальное значение лесов для страны не только как источника ценнейшего сырья, но и как важного компонента биосферы, во многом определяющего условия жизни на Земле. Сохранение лесов на территории России имеет ключевое значение для поддержания экологического баланса, защиты биоразнообразия и смягчения последствий изменения климата. В связи с этим, особенно актуальным становится необходимость развития дистанционных систем мониторинга состояния лесных экосистем, в частности распространения эпифитотий, что позволяет своевременно выявлять и предотвращать угрозы, обеспечивая защиту лесов и их экосистемных функций. Эффективный мониторинг позволит не только улучшить управление лесными ресурсами, но и принимать обоснованные решения по их охране и восстановлению.

На территории Российской Федерации отмечаются массовые усыхания древостоя, которые вызваны воздействием патогенных организмов. Причинами деградации древостоев являются насекомые (короед-типограф *Ips typographus*, короед союзный *Ips amitinus* [2-4]; сибирский шелкопряд *Dendrolimus sibiricus* [5], непарный шелкопряд *Lymantria dispar* [6] и др.), грибные инвазии (корневая губка *Heterobasidion annosum* и др.) [7-9].

Кроме эпифитотий, вызванных насекомыми и грибными инвазиями, имеют широкое распространения и бактериальные инфекции древостоя. Так в Республике Татарстан отмечено распространение бактериальной водянки осины [10]. В Республике Башкортостан [11], Донецкой Народной Республике [12] и других регионах широко встречается заболевание березовых древостоев, вызванное действием бактерии *Erwinia multivora*.

Оперативное обнаружение эпифитотий обеспечивается методами дистанционного зондирования Земли. Например, для выявления очагов заражения короедом-типографом использовались подходы классификации снимков Landsat 7 (каналы 3, 4, 5) методом ISODATA, а также вегетационные индексы NDVI и SWVI [2, 13]. В Алтайском крае для обнаружения участков, зараженных полиграфом уссурийским (*Polygraphus proximus*), применялись как автоматические, так и визуальные методы дешифрирования изображений Sentinel-2 и Канопус-В [14].

В отличие от эпифитотий, вызванных насекомыми, очаги, обусловленные бактериальными инфекциями, такими как бактериальная водянка березы, хуже визуализируются на инфракрасных изображениях. Более эффективно такие эпифитотии выявляются на оптических космических снимках высокого разрешения (1 м и более) и изображениях, полученных с помощью беспилотных летательных аппаратов (БПЛА). Однако ручная оцифровка таких снимков требует много времени и может быть недостаточно точной.

Целью настоящего исследования является разработка программного модуля для автоматизации процесса идентификации сухостойных деревьев на основе данных дистанционного зондирования Земли и тестирование программного модуля на различных типах исходных данных для наиболее точного обнаружения сухостойных вершин. Результаты работы могут быть использованы государственными и муниципальными службами, осуществляющими деятельность по предупреждению возникновения лесных пожаров, а также ведомствами, выполняющими функции по защите лесного хозяйства от распространения вредителей леса.

Материалы и методы исследования

Объектами исследования являются лесные массивы средневозрастных березовых древостоев, расположенные в Туймазинском районе Республики Башкортостан на территории природ-

ного парка «Кандры-Куль» и в Салаватском районе Республики Башкортостан на территории глобального геопарка ЮНЕСКО «Янган-Тау» (рис. 1).

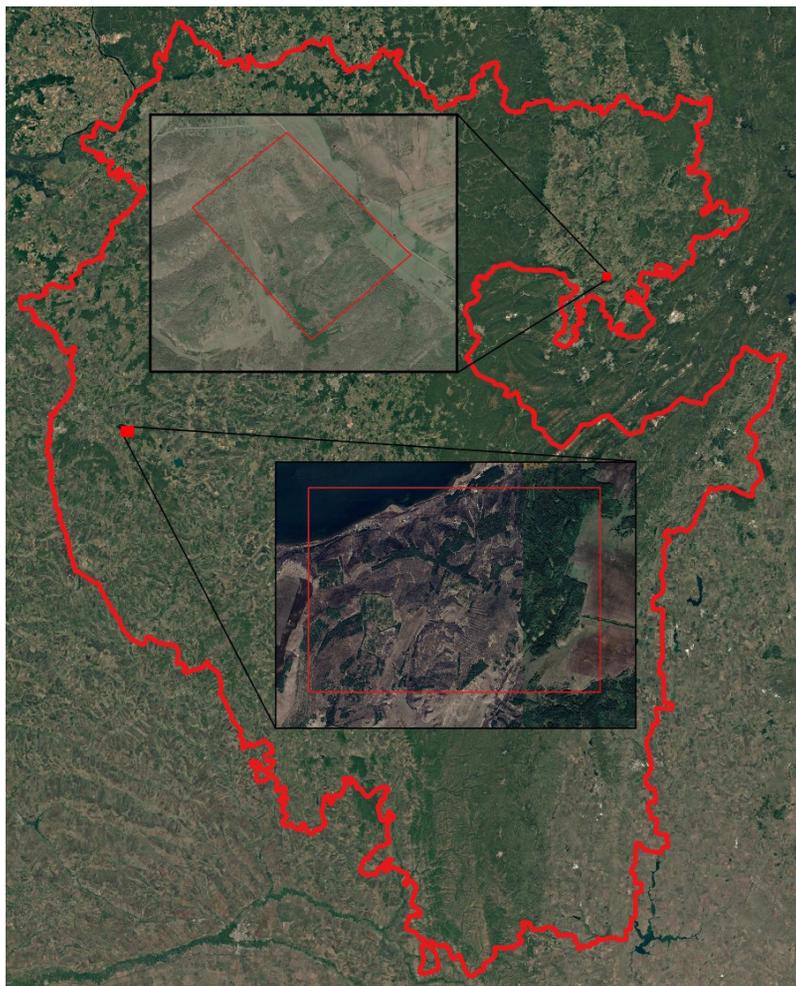


Рис. 1. Объекты исследования

Figure. 1. Objects of research

Оперативный мониторинг и съемка объектов исследования выполнялись беспилотным воздушным судном самолетного типа Geoscan 201M с оптической камерой Sony DSC-RX1RM2 в режиме визуального контроля на высотах, не превышающих 150 м. Условия и общие параметры съемки объектов исследования приведены в табл. 1.

Таблица 1 – Условия съемки объектов исследования

Table 1 – Conditions for shooting the objects of investigation

Параметр	Природный парк «Кандры-Куль»	Глобальный геопарк ЮНЕСКО «Янган-Тау»
Период съемки	Июнь 2024 г.	Сентябрь 2024 г.
Погодные условия	Температура воздуха +25 С°, переменная облачность, без осадков, скорость ветра – 2-4 м/с без порывов	Температура воздуха +16 С°, ясно, без осадков, скорость ветра – 1-2 м/с без порывов
Общее время полета	97 минут	46 минут
Площадь съемки	7,236 км ²	2,450 км ²

В результате камеральной обработки получены фотопланы объектов исследования – лесных массивов, с пространственным разрешением 2,9 см/пикс (рис. 2 и 3).

Современные методы искусственного интеллекта в сочетании с методами глубокого обучения с высокой точностью и надежностью позволяют автоматизировать обнаружение сухостойных деревьев. Две основные задачи, которые решают нейронные сети в этой области, – это обнаружение объектов и сегментация.



Рис. 2. Природный парк «Кандры-Куль»
Figure 2. Kandy-Kul Natural Park



Рис. 3. Глобальный геопарк ЮНЕСКО «Янган-Тау»
Figure 3. Yangan-Tau UNESCO Global Geopark

Модели обнаружения объектов, такие как YOLO (You Only Look Once), фокусируются на идентификации и локализации определенных объектов на изображении. Эти модели выводят ограничивающие рамки вокруг интересующих объектов (в данном случае деревьев) и классифицируют, являются ли деревья здоровыми или пораженными. Основой обнаружения объектов являются сверточные нейронные сети (CNN). Расширенные версии, такие как YOLOv8, хорошо подходят для задач обнаружения в реальном времени благодаря своей скорости и точности. Модели обнаружения объектов можно обучить идентифицировать и выявлять сухостойные деревья, отмечая их местоположение на карте.

В то время как обнаружение объектов идентифицирует и локализует деревья, сегментация изображения обеспечивает точность на уровне пикселей. Сегментация делит изображение на отдельные области, присваивая каждому пикселю метку: здоровый, больной. Для задач сегментации используются полностью сверточные сети (FCN), U-Net и Segformer. Например, при обнаружении сухостойных вершин деревьев сегментация может использоваться для изоляции точных областей поражения на каждом дереве, обеспечивая более подробную информацию, чем простое обнаружение объектов, поскольку она определяет, какая часть кроны дерева поражена.

Для решения задачи вместо написания собственной модели с разработанной структурой можно использовать предварительно обученные модели для точной настройки на меньшем наборе данных изображений деревьев для повышения производительности при выполнении определенных задач, таких как обнаружение признаков усыхания деревьев. Это снижает потребность в больших наборах данных и ускоряет процесс обучения.

Объединение данных из нескольких источников (например, видеоматериалов с БПЛА и спутниковых снимков) повышает способность модели обнаруживать пораженные деревья.

Для создания набора данных нами был выбран метод обнаружения объектов, который, по сравнению с методом сегментации изображений, обеспечивает более эффективную разметку.

Результаты и их обсуждение

Для исследования использован набор данных, состоящий из 100 изображений с высоким разрешением (8000x6000 пикселей), включающим кадры лесных массивов с камеры БПЛА, пораженных бактериальной водянкой. Эти изображения были выбраны для обеспечения подробного обзора отдельных деревьев, что позволяет точно обнаруживать и анализировать заболевание.

Вместо использования обычных инструментов маркировки, таких как Roboflow, мы выбрали Label Studio – более подходящий вариант для работы с изображениями большого размера. Способность Label Studio эффективно обрабатывать изображения высокого разрешения имела решающее значение, поскольку она позволяет нам сохранять полную детализацию набора данных без необходимости уменьшать масштаб или преждевременно разделять изображения во время процесса маркировки. Набор данных был тщательно аннотирован путём маркировки усыхающих деревьев, что позволило создать полный и подробный обучающий набор данных.

Чтобы решить задачу обнаружения сухостойных вершин пораженных деревьев, были обучены четыре сети YOLOv8 с различными конфигурациями: две средние модели (YOLOv8m – Medium) и две большие модели (YOLOv8l – Large). Мы применили два различных подхода к обучению:

1) Нарезка данных с помощью метода скользящего окна: в этом подходе исходные изображения 8000x6000 были разрезаны на более мелкие части 1280x1280 пикселей с помощью алгоритма скользящего окна, поскольку это позволило сети обрабатывать набор данных управляемыми фрагментами без потери разрешения. Этот метод был разработан для захвата мелких деталей, которые могли быть упущены в сжатом изображении.

2) Второй подход включал сжатие всего изображения 8000x6000 до разрешения 1280x1280. Это сохраняло общую структуру изображения, но уменьшало разрешение, что упрощало обработку модели YOLOv8. Однако сжатие может привести к некоторой потере мелких деталей.

Для обоих подходов – скользящего окна и сжатия разрешения – мы обучили среднюю и большую модель. Это позволило провести комплексное сравнение размеров моделей и методов подготовки изображений с целью определения наиболее эффективной комбинации для точного обнаружения пораженных деревьев.

Ниже представлена сравнительная таблица (табл. 2), основанная на показателях точности (ассурагу) для четырех моделей YOLOv8.

Таблица 2 – Показатели точности для моделей YOLOv8

Table 2 – Accuracy Metrics for YOLOv8 Models

YOLO	Скользящее окно	Сжатие разрешения
Medium	0,54	0,49
Large	0,63	0,62

Близкое качество обеих моделей семейства YOLOv8 – Large показало необходимость проверить результаты моделей на реальных данных.

Метрики, представленные на рис. 4, дают подробное представление о ходе обучения и проверки модели YOLOv8, особенно фокусируясь на следующих ключевых аспектах:

а) Потери при обучении:

train/box_loss: потери рамки измеряют, насколько хорошо модель предсказывает местоположения ограничивающих рамок для деревьев. Постоянное снижение говорит о том, что модель становится лучше в точной локализации деревьев по мере обучения. Кривая сходится, что является хорошим признаком.

train/cls_loss: потери классификации, которые измеряют, насколько хорошо модель классифицирует деревья как здоровые или пораженные. Постоянное снижение говорит о том, что модель улучшает идентификацию правильных меток.

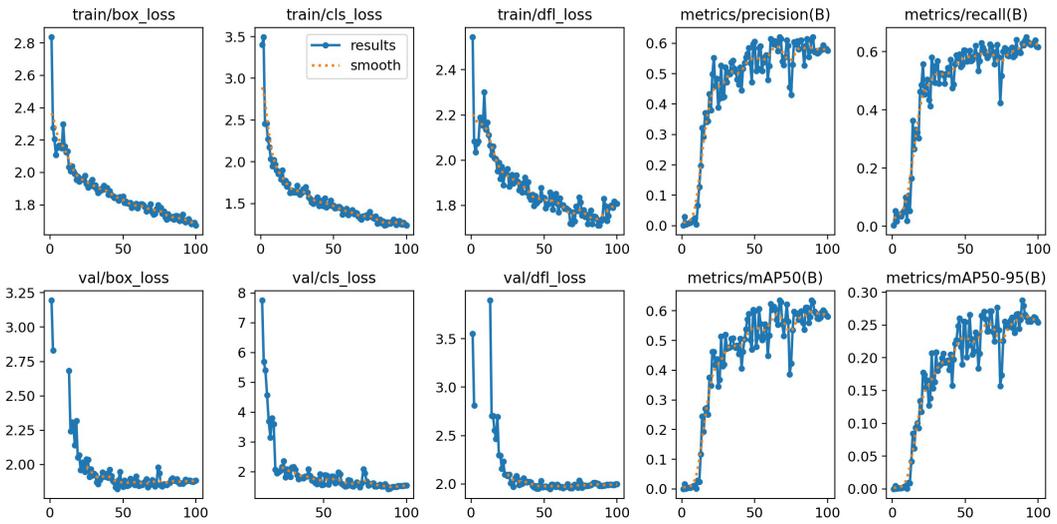


Рис. 4. Графики обучения YOLOv8l
Figure 4. YOLOv8l training schedules

train/dfl_loss: потери распределения очага (DFL) фокусируются на улучшении качества регрессий ограничивающих рамок. Убывающая кривая здесь говорит об улучшениях в тонкой настройке границ обнаружения объектов.

б) Потери при валидации:

val/box_loss: отслеживает, насколько хорошо модель обобщает свои прогнозы ограничивающего прямоугольника на невидимые данные проверки. Нисходящая тенденция является положительным показателем, показывающим, что производительность модели улучшается на наборе проверки.

val/cls_loss: аналогично train/cls_loss, но для данных проверки. Резкое снижение на раннем этапе является многообещающим, и модель хорошо стабилизируется к концу обучения.

val/dfl_loss: снова, сосредоточившись на качестве прогнозов ограничивающего прямоугольника, это показывает устойчивое снижение, что указывает на улучшение обобщения модели.

с) Точность, полнота и метрики mAP (верхняя и нижняя строки):

metrics/precision(B): точность измеряет, сколько деревьев, обнаруженных как пораженные, были правильно идентифицированы. Точность начинается с низкого значения, но последовательно улучшается, стабилизируясь около 0,6. Это говорит о том, что модель становится более надежной в обнаружении фактически больных деревьев по мере обучения.

metrics/recall (B): recall измеряет, сколько фактически затронутых деревьев было успешно обнаружено. Он неуклонно растет и достигает пика около 0,65. Тенденция к росту показывает, что модель становится лучше в поиске всех затронутых деревьев.

metrics/mAP50 (B): mean Average Precision при 50 % IoU (пересечение по объединению) показывает, насколько хорошо модель обнаруживает деревья в пределах допустимых перекрытий ограничивающих рамок. Кривая, поднимающаяся к 0,65, указывает на хорошую локализацию для большинства деревьев.

metrics/mAP50-95 (B): более строгая метрика mAP (в диапазоне от 50 % до 95 % порогов перекрытия IoU) неуклонно растет и стабилизируется около 0,25-0,30. Это более жесткий критерий, поэтому ожидается более низкое значение.

Модель хорошо обучается и улучшает локализацию ограничивающего прямоугольника и классификацию как на обучающих, так и на проверочных данных.

Показатели точности, полноты и mAP указывают на то, что модель может надежно обнаруживать и классифицировать пораженные деревья. Устойчивое улучшение и сходимость как в

кривых потерь обучения, так и в кривых потерь проверки свидетельствуют о том, что модель не переобучается, но может выиграть от дальнейшего обучения для полной стабилизации, особенно в отношении точности.

На рис. 5 представлены результаты обнаружения для модели YOLOv8 – Large с использованием срезов данных, которые показывают, что модель не может идентифицировать большинство деревьев, пораженных бактериальной водянкой. Единственный ограничивающий прямоугольник на изображении объединяет множество объектов: модель распознала объект, но пропустила большинство больных деревьев. Такая низкая эффективность связана с несколькими факторами, включая сложность среды, ограниченную способность модели фиксировать мелкие детали.

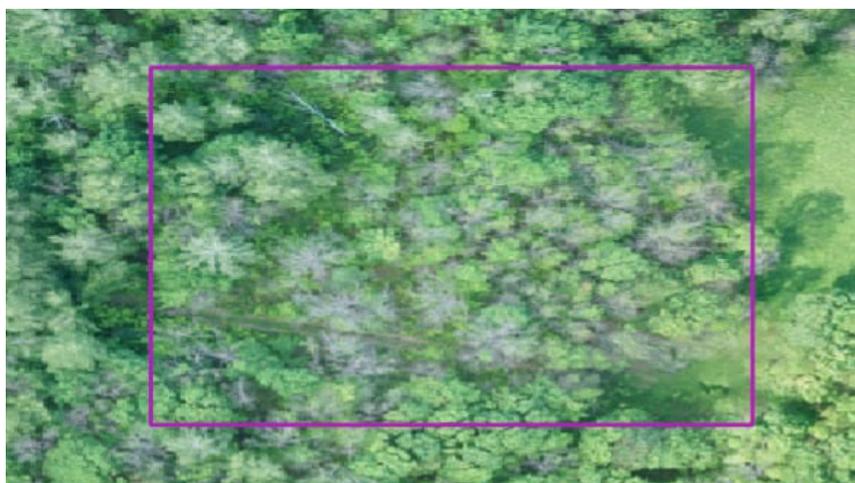


Рис. 5. Распознавание фрагмента с использованием нарезанных данных

Figure 5. Fragment recognition using cropped data

На рис. 6 представлены результаты обнаружения для модели YOLOv8 – Large с использованием сжатых данных. Эта модель смогла обнаружить значительно большее количество больных деревьев, на что указывает плотное распределение ограничивающих прямоугольников по лесной территории. Несмотря на сжатие при обучении исходных изображений 8000x6000 до 1280x1280 пикселей, большая модель сохранила свою способность идентифицировать зараженные деревья на комплексном ортофотоплане, что говорит о том, что данный метод более эффективен при обработке сложных, высокоплотных областей интереса.



Рис. 6. Распознавание фрагмента с использованием сжатых данных

Figure 6. Fragment recognition using compressed data

Модель срезов данных обнаруживает очень мало больных деревьев, при этом большие участки леса остаются немаркированными, показывая, что способность модели обобщать более мелкие участки изображения ограничена.

Модель сжатых данных демонстрирует превосходное обнаружение, успешно идентифицируя большое количество больных деревьев. Даже со сжатыми изображениями более крупная модель отлично различает деревья, пораженные болезнью.

Это сравнение показывает, что, хотя срезы данных могут сохранять детали изображения, для обработки сложного обнаружения деревьев на снимках густого леса, особенно для задач обнаружения тонких заболеваний, необходима более крупная модель с большей емкостью.

На рис. 7 и 8 представлены результаты вывода модели на одном и том же участке карты, но из двух разных источников: спутниковые снимки и кадры съёмки с БПЛА. Оба изображения охватывают одну и ту же область, однако видно, что качество и детализация обнаружения значительно различаются между ними.



Рис. 7. Фрагмент спутникового снимка
Figure 7. Fragment of satellite image



Рис. 8. Фрагмент снимка с БПЛА
Figure 8. Fragment of an image with using UAV

Спутниковый снимок обеспечивает более широкую область поиска и идентификации, что делает его пригодным для крупномасштабного мониторинга. Однако из-за большой высоты и ограниченного разрешения по сравнению со снимками с БПЛА, производительность модели,

как правило, менее точна. Обнаружение небольших отдельных сухостойных деревьев является более сложной задачей, поскольку меньшее пространственное разрешение (>30 сантиметров на пиксель) затрудняет различение тонких деталей, таких как изменение текстуры и цвета дерева. Следовательно, модель может пропустить больные деревья или перепутать здоровые с зараженными из-за недостатка данных.

Напротив, результаты, полученные с помощью беспилотных летательных аппаратов, демонстрируют значительно более высокий уровень точности и детализации. Использование БПЛА на малых высотах позволяет получать изображения с высоким разрешением, что облегчает обнаружение больных деревьев за счёт более детального изучения структуры леса и характеристик отдельных деревьев. Снимки с БПЛА в высоком разрешении позволяют лучше различать тонкие особенности, такие как текстура и цветовые вариации, что приводит к увеличению количества правильно обнаруженных больных деревьев. Кроме того, улучшенная производительность обнаружения также подчеркивает способность модели работать лучше при наличии высококачественных данных, что позволяет ей более четко различать здоровые и зараженные деревья.

Использование данных съемки с БПЛА показало свою эффективность для определения структуры древостоя [15-19]. Высокая детализация позволяет выделять угнетенных древостой как визуальными [15], так и медами машинного обучения с применениями нейронных сетей [16-19]. Последние демонстрируют высокую эффективность. В работе Иванова и др. (2018) [16] показано, что при сопоставлении результатов с данными наземных исследований и ортофотопланом (полученном в результате съемки с БПЛА) из 241 найденного алгоритмом дерева 175 обнаружены корректно (72,6 %).

Как было сказано выше особую эффективность в определении древостоя, поврежденного короедом *Polygraphus Proximus* Blandford продемонстрировало использование глубоких нейронных сетей You Only Look Once (YOLO) [17-19]. В частности, эксперименты показывают, что YOLOv4 достигает особенно хороших результатов при применении предварительной обработки BCET [17]. Наилучший результат тестирования при сравнении моделей YOLO был получен для YOLOv4 со средней точностью до 95 %. При этом попиксельная классификация видов мультиспектральных изображений может быть выполнена с общей погрешностью около 1 %, что значительно меньше, чем при обработке изображений в формате RGB [19]. Наши результаты также демонстрируют эффективность применения нейронных сетей YOLO.

Заключение

В данном исследовании были изучены методы обнаружения сухостойных деревьев с использованием комбинации спутниковых и беспилотных снимков, а также различных подходов глубокого обучения. После анализа различных стратегий обнаружения и сегментации, включая традиционные методы компьютерного зрения и нейронные сети на основе искусственного интеллекта, мы выбрали обнаружение объектов в качестве основного метода за его эффективность в маркировке и способность предоставлять данные о количестве деревьев.

Было реализовано четыре модели с использованием архитектуры YOLOv8, обучены две средние и две большие модели. Обучение проводилось на наборе данных, состоящем из изображений высокого разрешения, обработанных двумя способами: нарезка изображений на более мелкие части с помощью скользящего окна и сжатие исходных изображений до 1280x1280 пикселей для прямой маркировки. Подход скользящего окна показал себя лучше, особенно на больших моделях, поскольку он сохранял более высокое разрешение изображения и приводил к более точному обнаружению.

Сравнительный анализ результатов, полученных на основе спутниковых снимков и снимков, сделанных с использованием беспилотных летательных аппаратов выявил ключевое различие. Данные с БПЛА показывают значительно лучшее обнаружение благодаря более высокому разрешению и более мелким деталям, что позволяло модели точнее идентифицировать больные деревья. Спутниковые снимки, напротив, обеспечивают лучшее покрытие больших террито-

рий, но были менее эффективны при обнаружении отдельных зараженных деревьев из-за более низкого разрешения.

Таким образом, сочетание метода обнаружения объектов со снимками высокого разрешения, полученными с применением БПЛА, оказалось наиболее эффективным методом для точного обнаружения сухостойных деревьев.

Литература

1. Пыжев, А. И. Лесные ресурсы Азиатской России: богатство или дефицит? / А. И. Пыжев, Е. А. Сырцова, Е. В. Зандер. – Текст : непосредственный // Журнал Сибирского федерального университета. Серия : Гуманитарные науки. – 2022. – Т. 15, № 12. – С. 1841-1853.
2. Малахова Е. Г. Распространение и структура очагов усыхания еловых лесов Подмосковья в 2010-2012 годах / Е. Г. Малахова, Н. И. Лямцев. – Текст : непосредственный // Известия Санкт-Петербургской лесотехнической академии. – 2014. – № 207. – С. 193-201.
3. Миртова, И. А. Использование спутниковых данных для оценки повреждения лесов короедом-типографом на примере Московской области / И. А. Миртова, Д. В. Ершов, Д. А. Мягкова. – Текст : непосредственный // Известия высших учебных заведений. Геодезия и аэрофотосъемка. – 2013. – № 6. – С. 77-82.
4. Гниненко, Ю. И. Возможности использования космических снимков для слежения за очагами союзного короеда / Ю. И. Гниненко, В. А. Иванов. – Текст : непосредственный // Актуальные проблемы лесного комплекса. – 2022. – № 62. – С. 137-142.
5. Кархова, С. А. Оценка лесопатологического состояния кедровых лесов Иркутской области / С. А. Кархова, Е. Б. Никитенко. – Текст : непосредственный // Известия Байкальского государственного университета. – 2023. – Т. 33, № 2. – С. 380-393.
6. Колтунов, Е. В. Спектральный анализ многолетней динамики вспышек массового размножения непарного шелкопряда (*Lymantria dispar* L.) на Урале / Е. В. Колтунов, Л. Н. Ермаков. – Текст : непосредственный // Современные проблемы науки и образования. – 2013. – № 2. – С. 399.
7. Маслов, А. Д. Размножение стволовых вредителей ели в очагах корневых гнилей / А. Д. Маслов. – Текст : непосредственный // Защита леса от вредителей и болезней: сборник трудов ВНИИЛМ. Москва : Лесная промышленность. – 1973. – С. 84–10.
8. Колганихина, Г. Б. К изучению проблемы усыхания вязов в Москве и Подмосковье / Г. Б. Колганихина, В. В. Синькевич. – Текст : непосредственный // Труды Санкт-Петербургского научно-исследовательского института лесного хозяйства. – 2021. – № 3. – С. 67-85.
9. Оценка роли насекомых и дендропатогенных организмов в усыхании древостоев Ленинградской области и Республики Татарстан / А. В. Селиховкин, Р. В. Глебов, Н. Г. Магдеев [и др.]. – Текст : непосредственный // Лесоведение. – 2016. – № 2. – С. 83–95.
10. Сингатуллин, И. К. Состояние осинников Республики Татарстан после засухи 2010 года / И. К. Сингатуллин. – Текст : непосредственный // Вестник Казанского ГАУ. – 2016. – № 3 (41). – С. 40–45.
11. Влияние климатических изменений на распространение бактериальной водянки березы / Е. А. Богдан, Р. Г. Камалова, Л. Н. Белан, И. О. Туктарова. – Текст : непосредственный // Географический вестник. – 2024. – № 1(68). – С. 151-165.
12. Бондаренко-Борисова, И. В. Бактериальная водянка – опасное заболевание березы в Донском регионе / И. В. Бондаренко-Борисова. – Текст : непосредственный // Промышленная ботаника. – 2020. – Вып. 20. – № 2. – С. 62-65.
13. Алексеев, А. С. Выявление ранних стадий повреждения еловых древостоев короедом-типографом на основе совмещенного анализа материалов спутниковой съемки Sentinel-2b и наземных обследований / А. С. Алексеев, Д. М. Черниховский. – Текст : непосредственный // Известия Санкт-Петербургской лесотехнической академии. – 2023. – № 246. – С. 22-43.
14. Долгачева, Л. Е. Оценка повреждений лесных насаждений Горно-Кольванского лесничества Алтайского края полиграфом уссурийским с применением данных дистанционного зондирования /

Л. Е. Долгачева, И. Н. Ротанова. – Текст : непосредственный // Успехи современного естествознания. – 2023. – № 7. – С. 21-26.

15. Санников, И. Ю. Выявление и анализ сухостоя при помощи беспилотного летательного аппарата / И. Ю. Санников, Д. Н. Андреев, С. А. Бузмаков. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2018. – Т. 15, № 3. – С. 103-113. – DOI 10.21046/2070-7401-2018-15-3-103-113.

16. Иванова, Н. В. Определение характеристик смешанных древостоев по данным аэрофото-съёмки с применением беспилотного летательного аппарата (БПЛА) / Н. В. Иванова, М. П. Шашков, В. Н. Шанин // Вестник Томского государственного университета. Биология. – 2021. – № 54. – С. 158-175. – DOI 10.17223/19988591/54/8.

17. Detection of Norway spruce trees (*Picea Abies*) infested by bark beetle in UAV images using YOLOs architectures / A. Safonova, Y. Hamad, A. Alekhina, D. Kaplun // IEEE Access. – 2022. – № . 10. – P. 10384-10392. – DOI: 10.1109/ACCESS.2022.3144433.

18. Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning / A. Safonova, S. Tabik, D. Alcaraz-Segura [et al.] // Remote Sensing. – 2019. – Vol. 11, № . 6. – P. 643. – DOI: 10.3390/rs11060643

19. Individual tree crown delineation for the species classification and assessment of vital status of forest stands from UAV images / A. Safonova, Y. Hamad, E. Dmitriev [et al.] // Drones. 2021. – Vol. 5, № . 3. – P. 77. – DOI: 10.3390/drones5030077

References

1. Pyzhev AI, Syrtsova EA, Zander EV. Forest resources of Asian Russia: wealth or scarcity? Journal of Siberian Federal University. Humanities & Social Sciences, 2022;15 (12):1841-1853. In Russia

2. Malakhova EG, Lyamtsev NI. Extent and structure of Moscow region spruce forest dieback in 2010-2012. Proceedings of the St. Petersburg Forestry Engineering Academy, 2014;207:193-201. In Russia

3. Mirtova IA, Ershov DV. The use of satellite data to assess damage to forests by bark beetles on the example of the Moscow region. News of higher educational institutions. Geodesy and aerial photography, 2013;6: 7-82. In Russia

4. Gninenko YuI, Ivanov VA. The possibilities of using satellite images to track the foci of the Allied bark beetle. Actual problems of the forest complex, 2022;62:137-142. In Russia

5. Karkhova SA, Nikitenko EB. Assessment of the forest-pathological condition of cedar forests of Irkutsk region. Bulletin of Baikal state university, 2023;33(2):80-393. In Russia

6. Koltunov EV, Erdakov LN. Spectral analysis of the long-term dynamics of outbreaks of mass reproduction of the unpaired silkworm (*Lymantria dispar* L.) in the Urals. Modern problems of science and education, 2013;2:399. In Russia

7. Maslov AD. Reproduction of spruce stem pests in foci of root rot. Forest protection from pests and diseases: proceedings of VNIILM. Moscow: Forest Industry, 1973:84–10. In Russia

8. Kolganikhina GB, Sinkevich VV. To the study of the problem of drying of elms in Moscow and the Moscow region. Proceedings of the Saint Petersburg forestry research institute, 2021;3:67-85. In Russia

9. Selikhovkin AV, Glebov RV, Magdeev NG, et al. Assessment of the role of insects and dendropathogenic organisms in the drying of stands of the Leningrad region and the Republic of Tatarstan. Forestry, 2016.;2:83-95. In Russia

10. Singatullin IK. The state of the aspen trees of the Republic of Tatarstan after the drought of 2010. Bulletin of the Kazan State Agrarian University, 2016;3(41):40-45. In Russia

11. Bogdan EA, Kamalova RG, Belan LN, Tuktarova IO. The influence of climatic changes on the spread of bacterial dropsy of birch. Geographical Bulletin, 2024;1(68):151-165. In Russia

12. Bondarenko-Borisova IV. Bacterial dropsy – a dangerous disease of birch in the Donetsk region. Industrial Botany, 2020;20(2):62-65. In Russia

13. Alekseev AS, Chernikhovskiy DM. Identification of the early stages of damage to spruce stands by bark beetles based on a combined analysis of Sentinel-2b satellite imagery and ground surveys. Proceedings of the Saint Petersburg Forestry Research Institute, 2023;246:22-43. In Russia
14. Dolgacheva LE, Rotanova IN. Assessment of damage to forest plantations of the Gorno-Kolyvan forestry of the Altai territory by the polygraphus proximus blandford using remote sensing data. Advances in current natural sciences, 2023;7:21-26. In Russia
15. Sannikov IYu, Andreev DN, Buzmakov SA. Identification and analysis of deadwood using an unmanned aerial vehicle. Cosmic Research, 2018;15(3):103-113. In Russia
16. Ivanova NV, Shashkov MP, Shanin VN. Obtaining tree stand attributes from unmanned aerial vehicle (UAV) data: the case of mixed forests. Tomsk State University Journal of Biology, 2021,54:158-175. In Russia
17. Safonova A, Hamad Y, Alekhina A, Kaplun D. Detection of Norway spruce trees (Picea Abies) infested by bark beetle in UAV images using YOLOs architectures. IEEE Access, 2022,10:10384-10392.
18. Safonova A, Tabik S, Alcaraz-Segura D [et al.] Detection of fir trees (Abies sibirica) damaged by the bark beetle in unmanned aerial vehicle images with deep learning. Remote Sensing, 2019,11(6):643.
19. Safonova A., Hamad Y., Dmitriev E. [et al.] Individual tree crown delineation for the species classification and assessment of vital status of forest stands from UAV images. Drones, 2021,5(3):77.

Сведения об авторах

ШАГАЛИЕВ Руслан Данифович – к.т.н., нач. межвузовской лаборатории климата и мониторинга углеродного следа, Уфимский государственный нефтяной технический университет». E-mail: shagaliev@rambler.ru

SHAGALIEV Ruslan D. – Candidate of Technical Sciences, head of the Interuniversity Laboratory of Climate and Carbon Footprint Monitoring, Ufa State Petroleum Technological University

БОГДАН Екатерина Александровна – к.э.н., в.н.с., Уфимский государственный нефтяной технический университет». E-mail: eavolkova@bk.ru

BOGDAN Ekaterina A. – Candidate of Economic Sciences, Leading Researcher, Ufa State Petroleum Technological University

ГАЛЯМОВ Айрат Фаритович – к.т.н., доцент, Уфимский государственный нефтяной технический университет. E-mail: galyamov.airat@gmail.com

GALYAMOV Airat F. – Candidate of Technical Sciences, Associate Professor, Ufa State Petroleum Technological University

БЕЛАН Лариса Николаевна – д.г.-м.н., дир. Центра технологий декарбонизации, Уфимский государственный нефтяной технический университет; проф. Уфимский университет науки и технологии. E-mail: belan77767@mail.ru

BELAN Larisa N. – Doctor of Geological and Mineralogical Sciences, Director of the Center for Decarbonization Technologies, Ufa State Petroleum Technological University

ИШКИНИНА Олеся Ивановна – к.х.н., доцент, Уфимский государственный нефтяной технический университет. E-mail: olesya-ioh@mail.ru

ISHKININA Olesya I. – Candidate of Chemical Sciences, Associate professor, Ufa State Petroleum Technological University, e-mail: olesya-ioh@mail.ru

ВАЛИЕВ Газиз Галимович – инженер-лаборант, Уфимский государственный нефтяной технический университет, доцент. E-mail: gaziz.valiev@yandex.ru

VALIEV Gaziz G. – laboratory engineer, Ufa State Petroleum Technological University