

Методы идентификации объектов лесного фонда с использованием технологий компьютерного зрения

Д.Б. Горохов^a, О.К. Даниленко^b, Д.С. Хлыстов^c

Братский государственный университет, ул. Макаренко, 40, Братск, Россия

^a gorokhov@brstu.ru, ^b olgdanilenko@yandex.ru, ^c xds1983@mail.ru

^a <https://orcid.org/0000-0001-7271-350X>, ^b <https://orcid.org/0000-0002-1308-2813>, ^c <https://orcid.org/0000-0001-8962-3631>

Статья поступила 28.01.2024, принята 06.02.2024

В статье рассматривается начальный этап исследовательской работы о способах внедрения методов машинного обучения в процессы лесопользования и ведения лесного хозяйства. На указанном этапе реализации научной работы целью является получение параметров настройки нейронной сети, достаточных для обнаружения и классификации заданных объектов интереса. Анализ большого количества публикаций по результатам научных исследований и нормативной документации показал перспективность рассматриваемого направления исследования. При проведении исследовательских работ были проанализированы различные методы автоматизированного обнаружения объектов, в итоге выбраны методы машинного обучения на базе языка программирования Python, являющегося на сегодняшний день одним из наиболее динамично развивающихся, с достаточным количеством базовых решений для реализации задач машинного обучения. В результате исследования, проведенного различными методами, были произведены сбор и оцифровка полевых материалов, их структуризация и обработка. Обработка полевого материала осуществлялась в процессе реализации программного кода на языке программирования Python. На начальном этапе работы объектами исследования являлись леса на территории Братского района Иркутской области. В результате обработки растровых изображений на тестовой выборке были получены местоположения распознаваемых объектов «дерево» с одновременным определением типа класса объекта, а также получены параметры обученной нейронной сети, необходимые для настройки процесса дешифрирования участка лесного фонда. Обученная нейронная сеть поможет в решении задачи автоматизации процесса сбора информации об объектах различного типа на территории лесного фонда при помощи беспилотных летательных средств для повышения эффективности процессов управления лесными ресурсами.

Ключевые слова: лесозаготовительное производство; лесной фонд; беспилотные летательные средства; Python.

Methods for identifying forest objects using computer vision technologies

D.B. Gorokhov^a, O.K. Danilenko^b, D.S. Khlystov^c

Bratsk State University; 40, Makarenko St., Bratsk, Russia

^a gorokhov@brstu.ru, ^b olgdanilenko@yandex.ru, ^c xds1983@mail.ru

^a <https://orcid.org/0000-0001-7271-350X>, ^b <https://orcid.org/0000-0002-1308-2813>, ^c <https://orcid.org/0000-0001-8962-3631>

Received 28.01.2024, accepted 06.02.2024

This article discusses the initial stage of research work on ways to introduce machine learning methods into forest management and forestry processes. The purpose of the study at this stage of the implementation of scientific work is to obtain parameters for setting up a neural network sufficient to detect and classify specified objects of interest. An analysis of a large number of publications based on the results of scientific research and regulatory documentation show the promise of this area of research. During the research work, various methods of automated object detection are analyzed, and as a result, machine learning methods are chosen based on the Python programming language, which is currently one of the most dynamically developing and has a sufficient number of basic solutions for implementing machine learning tasks. As a result of the research carried out by the authors of the article using various methods, field material is collected, digitized, structured and processed. Processing of field material is carried out in the process of implementing program code in the Python programming language. The objects of study at the initial stage of research work are forests in the Bratsk district of the Irkutsk region. As a result of processing raster images on a test sample, the locations of recognizable "tree" objects are obtained, while simultaneously determining the type of class of the object, and the parameters of the trained neural network are determined, necessary for setting up the process of deciphering a forest area. The trained neural network will help in solving the problem of automating the processes of collecting information about various types of objects in the forest fund using unmanned aerial vehicles (UAV) to increase the efficiency of forest resource management processes.

Keywords: logging production; forest fund; unmanned aerial vehicles; Python.

Введение. Вопрос возможности внедрения средств автоматизации в процессы дешифрирования снимков с беспилотных летательных средств (БЛС) и получения

обученных нейронных сетей (ОНС), необходимых для целей цифровизации процессов лесопользования, возник в процессе взаимодействия с производственной

сферой лесозаготовительной и лесохозяйственной деятельности. В процессе проведения многочисленных проверок соответствия материалов актуализированного лесоустройства с материалами натуральных обследований лесосек было выявлено, что оперативное управление лесным фондом как со стороны лесопользователя, так и со стороны территориальных органов управления лесным хозяйством в разрезе современных требований к организации производственной деятельности невозможно без внедрения высокотехнологичных методов получения информации о широком спектре показателей, которыми приходится оперировать в процессе реализации производственной деятельности.

Также с приходом понимания комплексности подхода к процессам лесопользования пришло понимание того, что на сегодняшний день наиболее конкурентноспособным является предприятие, в полной мере использующее достижения передовых технологий в сфере цифровизации технологических процессов лесопользования и лесного хозяйства [1].

В настоящее время территориальные органы управления лесным хозяйством и лесопользователи пытаются реализовать отладку механизма цифровизации лесного хозяйства путем внедрения трех государственных информационных систем для ведения лесного хозяйства:

- ЛесЕГАИС;
- ИСДМ-Рослесхоз;
- СЭД Рослесхоза [2].

Иркутская область и Бурятия не являются исключением в процессах реализации программ внедрения цифровых технологий в стратегически важные отрасли экономики. Однако наличие крупных лесопокрываемых территорий в Иркутской области при значительной степени устаревших лесоустроительных данных и отсутствии высокого технологического уровня оперативного контроля не способствуют эффективной реализации процессов трансформации.

Одной из основных проблем реализации программы цифровизации лесного хозяйства и лесопользования является получение достаточно достоверных актуальных данных о состоянии участка лесного фонда и его таксационных показателях с отслеживанием их динамики.

Лес как природная среда в процессе существования проходит как этапы естественного развития и роста, так и процессы стохастического характера — пожары, заболевания, ураганные ветры и т. д. Они также способствуют изменению таксационных показателей насаждений, снижению качества и количества товарной древесины на участке лесного фонда (пример приведен на рис. 1) и предварительно запланированному объему заготовки по породам, а также требуют увеличения трудозатрат на проведение лесосырьевой и технологической подготовки лесосеки к рубке ввиду повышения степени захламленности территорий (рис. 2).

Еще одной проблемой лесного фонда Иркутской области является высокий уровень зараженности деревьев стволовыми вредителями, в связи с чем на территории многочисленных лесничеств был объявлен карантин. Согласно нормативной документации [3], методика оценки состояния древесного фонда включает выезд на местность и оценку в полевых условиях лесопатологического состояния участка лесного фонда, для

чего не хватает человеческих ресурсов Рослесхоза, поскольку лесопатологическое обследование участка лесного фонда достаточно трудозатратно, малоавтоматизировано и должно производиться в бесснежный период, что также накладывает ограничения на сроки проведения работ и влияет на качество лесопатологического обследования. Пример закладки пробной площади для обследования участка, зараженного стволовыми вредителями, представлен на рис. 3.



Рис. 1. Пример снижения качества древесины на территории лесосеки по материалам натурального обследования лесосек (здесь и далее фото авторов статьи)



Рис. 2. Захламление лесосеки вследствие недавнего пожара на территории лесосеки по материалам натурального обследования лесосек



а)



б)

в)

Рис. 3. Пример повышения захламенности лесосеки (а) и снижения качества древесины (б, в) вследствие заражения стволовыми вредителями

Широкое применение в вопросах мониторинга пожаров и контроля очагов заражения насекомыми-ксилофагами нашли методы дистанционного зондирования Земли и использования результатов космосъемки. С расширением использования аэрокосмических методов и внедрения цифровой картографии стало возможным обследование здоровья и состояния значительных территорий лесного фонда. Именно на эти методы оценки состояния лесопокрываемых территорий опирается государственная инвентаризация лесов [4]. Зачастую она производится наземными и аэрокосмическими способами. Однако, как можно увидеть на рис. 4, точность совпадения естественных границ групп объектов и границ векторизованной информации при использовании результатов космосъемки зачастую составляет от 5 до 30 м, что является допустимым для целей мелко- и средмасштабного картографирования, тогда как лесопользователю в процессе реализации лесозаготовительных процессов необходима цифровая лесохозяйственная информация с более высокой точностью.

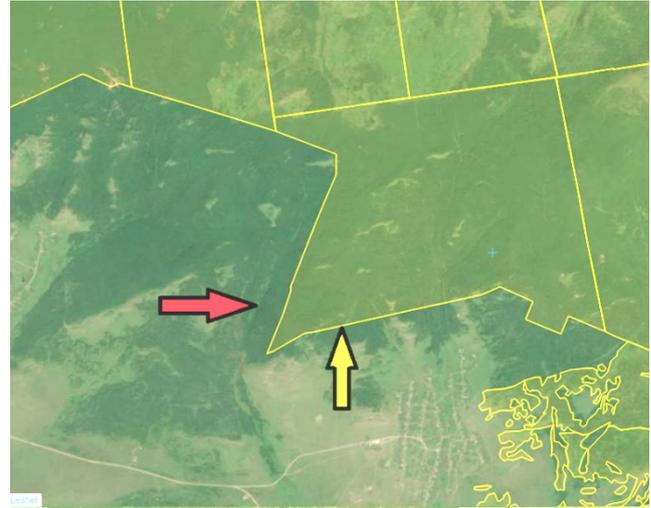


Рис. 4. Пример попытки решения задачи совмещения данных аэрокосмосъемки о местонахождении лесного массива с векторной информацией по материалам территориальных органов управления лесного хозяйства [5] (зеленой стрелкой обозначена граница лесного фонда по результатам векторизации материалов органов территориального управления лесного хозяйства, красной стрелкой — естественная граница лесного фонда)

Для оперативного контроля за выполняемыми на лесном участке процессами необходимо субдециметровое и субсантиметровое разрешение снимков. Уровень развития ДЗЗ и космосъемки в настоящее время позволяет получить изображение сверхвысокого разрешения, однако существует некоторое количество факторов, ограничивающих их повсеместное применение. К ним относятся высокая стоимость снимков сверхвысокого разрешения, невозможность коррекции траектории движения спутника, невозможность получения большого количества моментальных снимков поверхности земли в любой момент времени, снижение качества изображения снимка из-за дымки, зависимость качества снимка от погодных условий.

В результате возникают ошибки в сведениях, представленных в проектах освоения лесов, в рабочей документации на лесосечный фонд и, в конечном итоге, в количественных показателях в общей информационной базе государственного мониторинга лесов [6]. Многочисленные выезды на лесозаготовительные участки с закладкой пробных площадей (рис. 5) подтверждают необходимость проведения тщательного осмотра лесосеки в процессе ее отвода, что возможно качественно провести в ограниченный период времени и при небольших площадях лесосек.

Все вышеперечисленное свидетельствует о необходимости в ускорении получения и обработки геопространственной информации о состоянии лесного фонда для своевременного планирования производственных процессов и поддержания высокого уровня технического прогресса в лесозаготовительной и лесохозяйственной деятельности.



Рис. 5. Пример закладки пробной площади для актуализации данных лесопатологического обследования участка лесного фонда

На сегодняшний день наиболее широкое применение в практике сбора лесохозяйственной информации нашли беспилотные летательные средства (БЛС), позволяющие в кратчайшие сроки и с высокой точностью произвести осмотр больших по протяженности участков лесного фонда, что позволит сократить трудозатраты на проведение осмотра лесосек для оперативного планирования действий. Однако в настоящее время отсутствует законодательно утвержденная методика применения БЛС для автоматизированного получения лесохозяйственной информации, что связано, в первую очередь, с малым опытом использования данных технических средств для решения задач управления лесными ресурсами и малой изученностью процесса обработки полученной информации. Существующие программы автоматизированной обработки снимков с БЛС достаточно дорогостоящи, требуют определенного уровня технической подготовки специалиста, производящего обработку, и более ориентированы на решение картографических задач.

В связи с вышеперечисленным была поставлена цель проведения научного исследования по разработке методики сбора, подготовки, обработки лесохозяйственной информации средствами БЛС и получения итоговой обученной нейронной сети для автоматизации извлечения количественных и качественных показателей лесного фонда.

Материалы и методы. Исходными материалами исследования явились многочисленные снимки лесных насаждений в районе Братска и Братского района, выявление маркировочных признаков которых позволит оптимизировать процессы получения лесохозяйственной информации и повысить эффективность оператив-

ного управления производственными процессами на указанных территориях.

Методика исследования включает следующие этапы:

1. Подготовка набора данных. Для этой цели были произведены многочисленные вылеты БЛС с параллельным ведением видеозаписи в качестве не ниже HD. Съемка осуществлялась в период с 20.11.2020 по 25.12.2020 гг. квадрокоптером *DJI Phantom 4Pro* на различных высотах от 30, 50, 100, 150 м. Для формирования большого количества данных для обучения осуществлялось кадрирование видеоматериала, в результате чего получено большое количество изображений, пригодных для формирования тестовых и обучающих выборок.

2. Разметка обучающего материала. Поскольку на исследуемой территории внешний облик одних и тех же пород имеет большое разнообразие ввиду разновозрастной структуры и различного положения деревьев относительно съемочной оси, маркировка производилась вручную, путем векторизации места положения объекта «дерево» в приложении *LabelImg* с присваиванием класса в соответствии с породным составом. Полученный результат по определению классовой принадлежности сохранялся формате *PascalVOC*. В результате сохранения создается файл формата *.xml*, в котором в текстовом формате сохранялись данные о координатах местоположения векторных объектов. Пример маркированного изображения приведен на рис. 6



Рис. 6. Пример маркированного изображения

3. Обучение глубокой нейронной сети. В качестве языка программирования для обучения нейронной сети был выбран *Python*, исходя из наличия достаточного количества библиотек, значительно упрощающих процесс обучения нейронной сети для решения задач идентификации объектов и анализа изображений [7–11].

Наиболее подходящей архитектурой нейронной сети для решения задачи идентификации объектов на снимках является *YOLO v3*. Для успешного написания кода импортировались пакет *requirements.txt* и библиотека *Tensorflow*, *OpenCV*.

В качестве инструментального средства был выбран стек библиотек *Tensorflow – Keras – ImageAI* [12–14].

При написании программного кода авторы опирались на проект машинного обучения М. и Дж. Олафенва [15]. Созданная в проекте библиотека *ImageAI* позволяет поддерживать основной перечень наиболее вос-

требуемых алгоритмов машинного обучения для прогнозирования пользовательских изображений, обнаружения объектов на видео- и фотоизображениях, отслеживания видеообъектов и обучения прогнозированию изображений. Библиотека *ImageAI* также поддерживает обнаружение объектов, обнаружение видео и отслеживание объектов с использованием архитектур *RetinaNet*, *YOLOv3* и *TinyYOLOv3*, обученных на наборе данных. Также *ImageAI* позволяет обучать пользовательские модели обнаружению и распознаванию новых объектов. В библиотеке *ImageAI* реализована возможность формирования классов и методов для поиска изображений пользовательских объектов при использовании собственной модели ОНС, обученной с помощью класса *ImageAI Model Training*, а также можно использовать пользовательские модели, обученные с помощью *SqueezeNet*, *ResNet50*, *InceptionV3* и *DenseNet*, с созданием файла *JSON*, содержащего сопоставление наименований пользовательских объектов. Однако предложенное в проекте решение требовало существенной доработки, поскольку реализация непосредственного кода, предложенного в проекте, не давала нужного результата на заданных исходных данных.

При подготовке обучающего набора данных формируются файлы-аннотации в формате *xml* с заданными в них координатами очертаний крон деревьев с явным указанием класса, к которому принадлежат выделенные деревья.

После того, как сеть достигает удовлетворительной точности обнаружения, осуществляется варьирование значений параметров доверительной вероятности определения объекта (*SCORE_THRESHOLD*), желаемого пересечения по объединению порогового значения степени пересечения области поиска при сравнении требуемой и предсказанной сетью областей *IOU_THRESHOLD* или предсказанными сетью областями *NMS_THRESHOLD*. Выбираются те значения указанных параметров, которые обеспечивают максимальную точность *mAP*.

При реализации процесса обучения весь набор данных разбивался на две части — для обучения и тестирования во время обучения. В нашем случае для данного конкретного цикла обучения в обучающем наборе было взято более 800 снимков поверхности земли и более 400 снимков в тестовой выборке. Нейронная сеть — это функция от многих параметров, и необходимо найти такие значения параметров, чтобы уменьшить общую ошибку распознавания объектов. При переборе значений параметров ошибка может уменьшаться, а может и увеличиваться, ошибка может уменьшаться на изображениях, выбранных для обучения, но увеличиваться на изображениях, отложенных для тестирования. Динамика процесса обучений сохраняется в файлы контрольных точек *checkpoint*.

Вначале ошибки обучения и тестирования одинаково уменьшаются, но потом получается так, что ошибка обучения продолжает уменьшаться, а ошибка тестирования начинает увеличиваться. Точка, когда это проис-

ходит, и является точкой начала переобучения, это предел возможности обучения при заданных параметрах. Если качество обучения ниже заданного уровня, необходимо выполнить увеличение набора данных и повтор процесса обучения, сохранив веса сети предыдущего обучения, чтобы начать с них и сократить время идентификации объекта.

Из формируемых контрольных точек *ckpts* можно автоматизировать в *Python* процесс построения графика обучения.

Затем в командной строке запускается файл тестирования, результаты на выходе из которого автоматически выгружаются в папку *out*. Примеры результатов представлены на рис. 7 и 8.

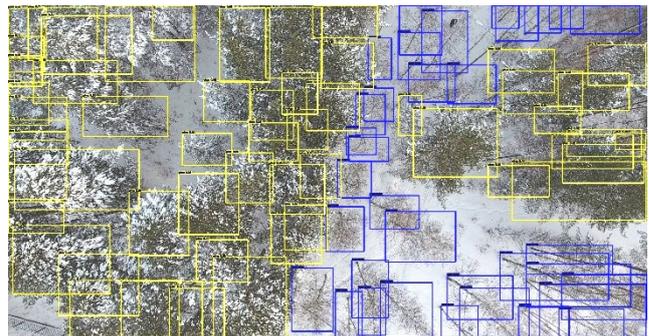


Рис. 7. Пример результата идентификации объектов в плотном насаждении на зимних снимках с предварительной сортировкой на хвойные и лиственные породы

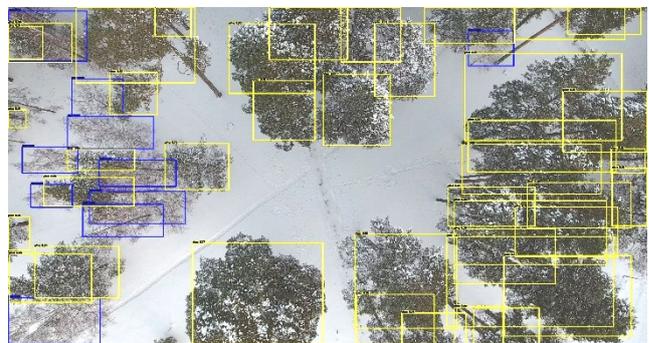


Рис. 8. Пример результата идентификации объектов на разреженном участке лесопарковой зоны с предварительной сортировкой на хвойные и лиственные

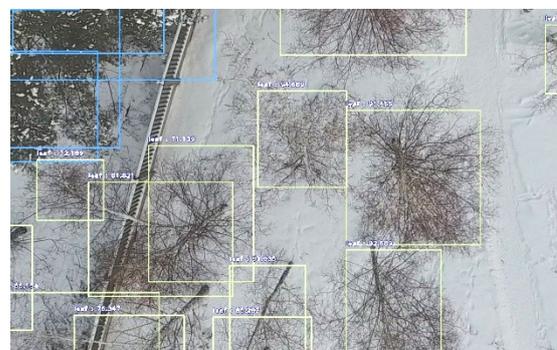


Рис. 9. Фрагмент изображения на выходе программы с указанием значения функции потерь по результатам 1 эпохи

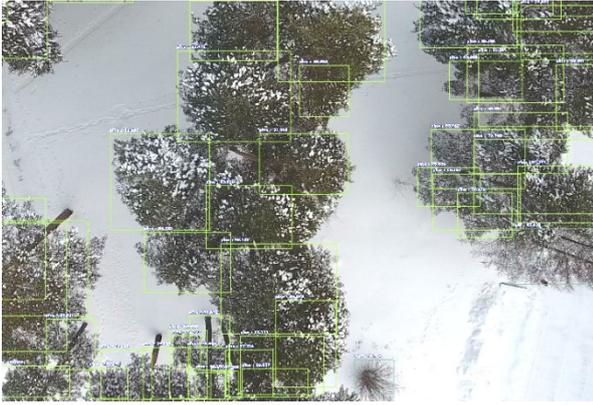


Рис. 10. Фрагмент изображения на выходе программы с указанием значения функции потерь по результатам 10 эпохи

Результаты исследований. В результате по каждому определяемому объекту определялась точность (*Precision* (P)) по следующей зависимости:

$$P_c = N(\text{TruePositives})_c / N(\text{TotalObjects})_c, \quad (1)$$

где $N(\text{TruePositives})_c$ — количество истинных положительных результатов прогнозирования изображения заданного класса C ; $N(\text{TotalObjects})_c$ — итоговое число определенных объектов в заданном классе изображений.

При наличии заданного класса, и наличия в объеме выборки тестового блока данных более 100 объектов с достоверным указанием, что заданный класс объекта имеется в наличии, вычисляется среднее из значений точности выборки с получением значения средней точности (*AveragePrecision* (AP)):

$$AP_c = \sum P_c / N(\text{TotalImages})_c, \quad (2)$$

где $\sum P_c$ — показатель точности прогнозирования всех объектов в тестовом наборе для определенного класса C ; $N(\text{TotalImages})_c$ — общее число изображений имеющих объекты класса C .

Полученные средние значения точности AP позволяют оценить производительность заданной категории модели.

Для оценки точности идентификации объектов в среднем по множеству классов определяемых объектов и решения этой задачи с заданным уровнем достоверности реализовывалась последовательность расчета неадекватного подавления NMS (*Non-Maximum Suppression*), геометрический смысл которой изображен на рис. 11.

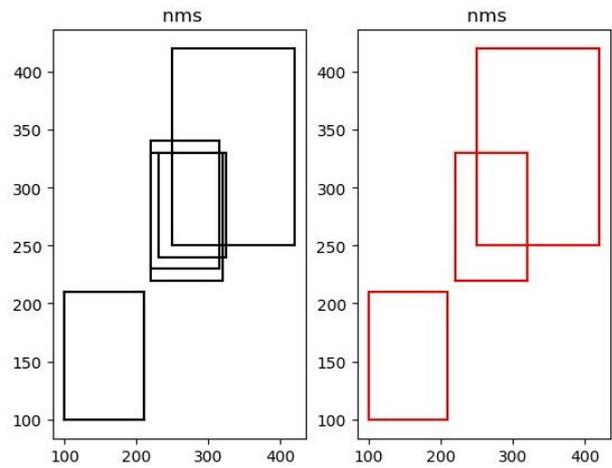


Рис. 11. Геометрический смысл последовательности расчета неадекватного подавления NMS [16]

По отобранным наибольшим пересечениям рассчитывался коэффициент совпадения IoU (*Intersection over Union*) с минимальным заданным пороговым значением $IoU = 0,4$.

Однако большое количество полученных средних значений точности усложняет процесс оценки точности прогнозирования местоположения объектов для всей модели, поэтому выбирается только одна метрика для их унификации — среднее значение средних значений точности всех классов, т. е. mAP (*Mean Average Precision*):

$$mAP = \sum AP_c / N(\text{Classes}), \quad (3)$$

где $N(\text{Classes})$ — количество всех классов объектов.

На графиках отображены результаты полученной функции mAP (ось аппликат) для тестовой выборки в зависимости от порога фиксированного уровня IoU к каждому классу (IoU threshold) и порога для принятия решения об удалении блоков на основе оценки $score$ threshold (рис. 12, а). На рис. 12, б показатели функции mAP (ось аппликат) для той же выборки в зависимости от порога для принятия решения об удалении блоков на основе оценки $score$ threshold и от порога фиксированного уровня NMS к каждому распознаваемому классу (NMS threshold), на данном графике зависимость получена при показателе NMS threshold = 0,3. На рис. 12, в отображена функция mAP при показателе NMS threshold = 0,2.

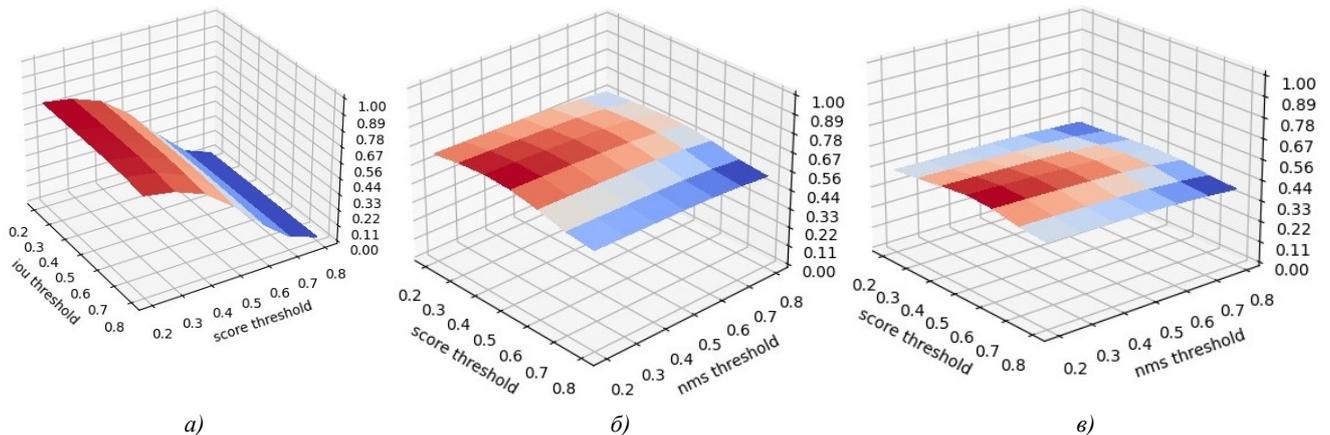


Рис. 12. Результаты расчета функции mAP от параметров валидации

По результатам валидации 20 эпох тестовой выборки изображений участков лесного фонда было получено, что только при параметрах тестовой выборки $NMS\ threshold = 0,2 \div 0,3$, $IoU = 0,4$ возможно получение результата прогнозирования местоположения объекта заданного класса с точностью более 80 %.

Заключение. В процессе проведения начального этапа исследовательских работ по возможности внедрения методов машинного обучения для повышения эффективности процесса цифровизации лесопользования и управления лесными ресурсами [17] было проанализировано большое количество литературных источников по тематике исследования. В результате было выявлено, что на сегодняшний день лесной комплекс является отраслью, наименее обеспеченной высокотехнологичными решениями на базе СНС [18]. В основном за основу для разработки СНС принимаются сети с архитектурой *ResNet50* и *ResNet101* [19; 20], однако ввиду массивности, большого количества вводимых параметров, а также длительности процесса обработки их проблематично использовать для оперативного

управления при реализации процессов лесопользования и ведения лесного хозяйства. На данном этапе проведения исследовательских работ наиболее подходящей архитектурой для решения вышеперечисленных задач является архитектура *Yolo v3*. Сравнительный анализ сроков обучения по традиционно применяемым СНС по сравнению с архитектурой *Yolo v3* показал уменьшение сроков обучения СНС на базе снимков сверхвысокого разрешения в пользу рекомендуемой до 3 раз. Однако рассматриваемая архитектура возможна к реализации только на снимках сверхвысокого разрешения. Попытка применить указанную архитектуру для обучения СНС на космических снимках высокого разрешения показала высокий уровень ошибок определяемых классов (более 50 %) и потерь, связанных с недостаточным для идентификации разрешением снимков [1]. Полученные на текущий момент параметры обученной сверточной нейронной сети позволят увеличить количество классов определяемых объектов с определением их характеристик, необходимых для процессов лесопользования и управления лесным хозяйством.

Литература

1. Горохов Д.Б., Даниленко О.К., Хлыстов Д.С. Технология автоматизации получения данных о лесных насаждениях для целей лесопользования // Системы. Методы. Технологии. 2021. № 2 (50). С. 169-174.
2. Сведения о государственных информационных системах Федерального Агентства Лесного Хозяйства 2019 год // Федеральное агентство лесного хозяйства. URL: <http://rosleshoz.gov.ru/opendata/7705598840-InformationSystems> (дата обращения: 17.12.2023).
3. Об утверждении порядка проведения лесопатологических обследований и формы акта лесопатологического обследования: приказ М-ва природных ресурсов и экологии Рос. Федерации от 16.09.2016 г. № 480.
4. О проведении государственной инвентаризации лесов: постановление Правительства Рос. Федерации от 26 июня 2007 г. № 407.
5. Демо-версия интерактивной карты ЛПК. URL: <https://lesprominform.ru/maps> (дата обращения: 20.12.2023).
6. Порядком осуществления государственного мониторинга земель, за исключением земель сельскохозяйственного назначения: приказ М-ва экономического развития Рос. Федерации от 26 дек. 2014 г. № 852.
7. Сафронова А.Н. Методы машинного обучения при обработке изображений сверхвысокого пространственного разрешения на примере задач классификации растительности: дис. ... на соиск. учен. степ. канд. техн. наук. Красноярск, 2019. 104 с.
8. Попов М.И., Миронов А.С. Сегментация изображений с использованием нейронных сетей // Информационные технологии XXI века: сб. науч. тр. Хабаровск, 2018. С. 53-62.
9. Сафонова А.Н., Табик С., Маглинец Ю.А. Сегментация оливковых деревьев с использованием нейронной сети Mask R-CNN // Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов» (SDM-2019): сб. тр. Всерос. конф. с междунар. участием (Бердск, 26-30 авг. 2019 г.). Новосибирск, 2019. С. 456-460.
10. Onishi M., Ise T. Automatic classification of trees using a UAV onboard camera and deep learning // arXiv:1804.10390. 2018.
11. Коэльо Л.П., Ричарт В. Построение систем машинного обучения на языке Python. 2-е изд. / пер. с англ. А.А. Слинкин. М.: ДМК Пресс, 2016. 302 с.
12. Tensorflow Documentation [Электронный ресурс]. URL: <https://www.tensorflow.org/> (дата обращения: 20.12.2023).
13. Keras Documentation [Электронный ресурс]. URL: <https://keras.io/> (дата обращения: 20.12.2023).
14. ImageAI Documentation [Электронный ресурс]. URL: <https://imageai.readthedocs.io/en/latest/> (дата обращения: 20.12.2023).
15. OlafenwaMoses. more theiaengine update [Электронный ресурс]. URL: <https://github.com/OlafenwaMoses/ImageAI> (дата обращения: 20.12.2023).
16. Python вычисляет iou и nms iou [Электронный ресурс]. URL: <https://russianblogs.com/article/31161252103/> (дата обращения: 20.12.2023).
17. О национальных целях развития Российской Федерации на период до 2030 года: указ Президента РФ от 21 июля 2020 г. № 474. URL: <http://base.garant.ru/74404210/#ixzz6tTRhHhSt> (дата обращения 25.12.2023).
18. Даниленко О.К., Сухих А.Н., Горохов Д.Б. Применение БЛПА для повышения эффективности лесозаготовительного производства в условиях истощенных лесосырьевых баз // Труды Братского гос. ун-та. 2020. Т. 1. С. 58-62.
19. Дмитриев Е.В., Козуб В.А., Мельник П.Г., Соколов А.А., Сафонова А.Н. Классификация и оценка состояния смешанных древостоев по аэроизображениям сверхвысокого пространственного разрешения // Изв. высш. учеб. заведений. Лесной журнал. 2019. № 5. С. 9-24.
20. Tokui S., Okuta R., Akiba T., Niitani Y., Ogawa T., Saito S., Suzuki S., Uenishi K., Vogel B., Yamazaki Vincent H. Chainer: A Deep Learning Framework for Accelerating the Research Cycle // Computer Science: Machine Learning, 2019. URL: <https://arxiv.org/abs/1908.00213> (дата обращения: 20.12.2023).

References

1. Gorokhov D.B., Danilenko O.K., Hlystov D.S. Automation technology for obtaining data on forest plantations for forest management purposes // *Systems Methods Technologies*. 2021. № 2 (50). P. 169-174.
2. Information about state information systems of the Federal Forestry Agency 2019 // Federal'noe agentstvo lesnogo hoz'yajstva. URL: <http://rosleshoz.gov.ru/opendata/7705598840-InformationSystems> (data obrashcheniya: 17.12.2023).
3. On approval of the procedure for conducting forest pathological examinations and the form of the forest pathological examination report: prikaz M-va prirodnih resursov i ekologii Ros. Federacii ot 16.09.2016 g. № 480.
4. On conducting a state forest inventory: postanovlenie Pravitel'stva Ros. Federacii ot 26 iyunya 2007 g. № 407.
5. Demo version of the interactive map of forestry complex. URL: <https://lesprominform.ru/maps> (data obrashcheniya: 20.12.2023).
6. Procedure for state monitoring of lands, with the exception of agricultural lands: prikaz M-va ekonomicheskogo razvitiya Ros. Federacii ot 26 dek. 2014 g. № 852.
7. Safronova A.N. Machine learning methods for processing images of ultra-high spatial resolution using the example of vegetation classification problems: dis. ... na soisk. uchen. step. kand. tekhn. nauk. Krasnoyarsk, 2019. 104 p.
8. Popov M.I., Mironov A.S. Image segmentation using neural networks // *Informacionnye tekhnologii XXI veka: sb. nauch. tr. Habarovsk*, 2018. P. 53-62.
9. Safonova A.N., Tabik S., Maglinec YU.A. Segmentation of olive trees using the Mask R-CNN neural network // *Obrabotka prostranstvennykh dannykh v zadachah monitoringa prirodnih i antropogennykh processov» (SDM-2019): sb. tr. Vseros. konf. s mezhdunar. uchastiem (Berdsk, 26-30 avg. 2019 g.)*. Novosibirsk, 2019. P. 456-460.
10. Onishi M., Ise T. Automatic classification of trees using a UAV onboard camera and deep learning // *arXiv:1804.10390*. 2018.
11. Koel'o L.P., Richart V. Building machine learning systems in Python. 2-e izd. / per. s angl. A.A. Slinkin. M.: DMK Press, 2016. 302 p.
12. Tensorflow Documentation [Elektronnyj resurs]. URL: <https://www.tensorflow.org/> (data obrashcheniya: 20.12.2023).
13. Keras Documentation [Elektronnyj resurs]. URL: <https://keras.io/> (data obrashcheniya: 20.12.2023).
14. ImageAI Documentation [Elektronnyj resurs]. URL: <https://imageai.readthedocs.io/en/latest/> (data obrashcheniya: 20.12.2023).
15. OlafenwaMoses. more theiaengine update [Elektronnyj resurs]. URL: <https://github.com/OlafenwaMoses/ImageAI> (data obrashcheniya: 20.12.2023).
16. Python vychislyayet iou i nms iou [Elektronnyj resurs]. URL: <https://russianblogs.com/article/31161252103/> (data obrashcheniya: 20.12.2023).
17. On the national development goals of the Russian Federation for the period up to 2030: ukaz Prezidenta RF ot 21 iyulya 2020 g. № 474. URL: <http://base.garant.ru/74404210/#ixzz6tTRhHhSt> (data obrashcheniya 25.12.2023).
18. Danilenko O.K., Suhiih A.N., Gorokhov D.B. The use of BLPA to improve the efficiency of logging production in the conditions of depleted forest resources // *Trudy Bratskogo gos. un-ta*. 2020. V. 1. P. 58-62.
19. Dmitriev E.V., Kozub V.A., Mel'nik P.G., Sokolov A.A., Safonova A.N. Classification and assessment of the state of mixed forest stands by aerial images of ultra-high spatial resolution // *Bulletin of higher educational institutions. Lesnoy zhurnal (Forestry journal)*. 2019. № 5. P. 9-24.
20. Tokui S., Okuta R., Akiba T., Niitani Y., Ogawa T., Saito S., Suzuki S., Uenishi K., Vogel B., Yamazaki Vincent H. Chainer: A Deep Learning Framework for Accelerating the Research Cycle // *Computer Science: Machine Learning*, 2019. URL: <https://arxiv.org/abs/1908.00213> (data obrashcheniya: 20.12.2023).