Трансформация экосистем
Ecosystem Transformation

ISSN 2619-0931 Online
www.ecosysttrans.com

Научная статья

Оценка качества автоматического детектирования деревьев по фотограмметрическим моделям высот и ортофотопланам

Н.В. Иванова[1]*, А.В. Лебедев[2, 3], М.П. Шашков[1]

[1] *Институт математических проблем биологии РАН – филиал ИПМ им. М.В. Келдыша РАН, 142290, Россия, Московская область, г. Пущино, ул. проф. Виткевича, д. 1*

[2] *Российский государственный аграрный университет – МСХА им. К.А. Тимирязева, 127434, Россия, г. Москва, ул. Тимирязевская, д. 49*

[3] *Государственный заповедник «Кологривский лес» им. М.Г. Синицына, 157440, Россия, Костромская обл., г. Кологрив, ул. Некрасова, д. 48*

**natalya.dryomys@gmail.com*

Поступила в редакцию: 18.04.2022
Доработана: 01.07.2022
Принята к печати: 04.07.2022
Опубликована онлайн: 02.06.2023

DOI: 10.23859/estr-220418
УДК 528.7:630*587.2

Аннотация. Работа выполнена в малонарушенном ельнике липняковом заповедника «Кологривский лес» (Костромская обл.) на основе данных аэрофотосъемки квадрокоптером. Алгоритмы автоматического детектирования позволили выделить большинство деревьев в пологе леса. Детектирование деревьев по ортофотоплану с использованием нейросетевого алгоритма Deep Forest оказалось более качественным, чем детектирование по модели высот при помощи алгоритма, основанного на методе скользящего окна. Как правило, оба метода демонстрировали более качественные результаты для хвойных деревьев по сравнению с лиственными. Сравнение средних высот деревьев, оцененных по дистанционным данным и измеренных наземными методами, не выявило значимых различий. Показана необходимость дополнительных наземных обследований для оценки качества детектирования подроста.

Ключевые слова: заповедник «Кологривский лес», квадрокоптер, нейронная сеть, Agisoft Metashape, lidR, rLiDAR, DeepForest

Для цитирования. Иванова, Н.В. и др., 2023. Оценка качества автоматического детектирования деревьев по фотограмметрическим моделям высот и ортофотопланам. *Трансформация экосистем* **6** (2), 33–48. https://doi.org/10.23859/estr-220418

Article

Evaluation of the quality of automatic tree detection using photogrammetric canopy height models and orthomosaic

Natalya V. Ivanova[1]*, Aleksandr V. Lebedev[2, 3], Maxim P. Shashkov[1]

[1] *Institute of Mathematical Problems of Biology RAS – the Branch of Keldysh Institute of Applied Mathematics of Russian Academy of Sciences, ul. professora Vitkevicha 1, Pushchino, Moscow Oblast, 142290 Russia*

[2] *Russian State Agrarian University - Moscow Timiryazev Agricultural Academy, ul. Timiryazevskaya 49, Moscow, 127434 Russia*

[3] *Kologrivsky Forest Nature Reserve, ul. Nekrasova 48, Kologriv, Kostroma Oblast, 157440 Russia*

**natalya.dryomys@gmail.com*

Received: 18.04.2022
Revised: 01.07.2022
Accepted: 04.07.2022
Published online: 02.06.2023

DOI: 10.23859/estr-220418
UDC 528.7:630*587.2

Translated by D.M. Martynova

Abstract. The work was performed in the old-growth linden-spruce forest of the Kologrivsky Forest Nature Reserve (Kostroma Oblast, Russia) based on aerial photography with a quadcopter. Automatic detection algorithms made it possible to detect most of the trees in the forest canopy. Tree detection by orthomosaic using neural network algorithm 'DeepForest' turned out to be of better quality than detection based on the canopy height model using an algorithm based on the sliding window method. As a rule, both methods showed better results for conifers compared to deciduous trees. Comparison of the average heights of trees estimated from remote data and measured by ground survey did not reveal significant differences. Additional ground surveys to assess the quality of undergrowth detection are needed.

Key words: Kologrivsky Forest Nature Reserve, quadcopter, neural network, Agisoft Metashape, lidR, rLiDAR, DeepForest

To cite this article. Ivanova, N.V. et al., 2023. Evaluation of the quality of automatic tree detection using photogrammetric canopy height models and orthomosaic. *Ecosystem Transformation* **6** (2), 33–48. https://doi.org/10.23859/estr-220418

Введение

Данные о пространственной структуре древостоев востребованы для решения множества фундаментальных и прикладных задач в области лесной экологии и лесоуправления (Alonzo et al., 2018; Bennett et al., 2020; Otero et al., 2018; Puliti et al., 2015). В то же время для получения надежных результатов необходим анализ больших объемов фактических данных о структуре древостоев и характеристиках отдельных деревьев, которые часто трудно получить, используя традиционные наземные методы исследований (Anderson and Gaston, 2013; Pajares, 2015; Zhang et al., 2016a). Перспективным подходом для оперативного сбора подобных данных является аэрофотосъемка беспилотными летательными аппаратами (БПЛА) – квадрокоптерами. Квадрокоптер производит съемку с одной контролируемой в процессе всего полета высоты, перемещаясь по заранее заданному маршруту, в автоматическом режиме выполняя серию фотографий с перекрытием при фиксированном угле ориентации камеры. Фотограмметрическая обработка этих изображений позволяет получать трехмерные облака точек,

двухмерные растровые RGB (Red, Green, Blue) ортофотопланы и цифровые модели высот (Digital Elevation Models), по которым можно оценить пространственное положение исследуемых объектов (в заданной системе координат), а также определить их размеры.

На основе облаков точек и моделей высот, используя готовые алгоритмы, можно в автоматическом режиме детектировать (находить) вершины деревьев, с высокой точностью оценивать их высоты, диаметры стволов и размеры крон (Иванова и др., 2021; Медведев и др., 2020; Birdal et al., 2017; Krisanski et al., 2020; Mohan et al., 2017). В то же время известные по литературным данным результаты в основном получены в моно- или олигодоминантных лесах, часто искусственного происхождения (Miller et al., 2017; Picos et al., 2020). Кроме того, качество детектирования и оценок высот деревьев с остроконечной кроной выше по сравнению с деревьями, имеющими шарообразную крону (Иванова и др., 2020; Alonzo et al., 2018; Bennett et al., 2020).

Для анализа структуры древостоев по ортофотопланам перспективны методы, основанные на искусственном интеллекте, компьютерном зрении и алгоритмах машинного обучения. В последние годы такие методы широко применяются в экологии для решения задач, связанных с анализом и сегментацией изображений (Christin et al., 2019; Lamba et al., 2019). Преимущество этого подхода заключается в том, что для анализа может быть использован накопленный массив изображений глобального охвата, в первую очередь, космические снимки (Weinstein et al., 2020). Так, например, Д.Е. Кисловым и К.А. Корзниковым (Kislov and Korznikov, 2020) при помощи нейронной сети выполнена оценка ветровальных нарушений по дистанционным данным. M. Onishi и T. Ise (2021) при помощи методов глубокого обучения успешно детектировали кроны деревьев по ортофотопланам в смешанных лесах Японии.

Целью данной работы стала оценка качества детектирования вершин деревьев по фотограмметрическим моделям высот и ортофотопланам. Исследование проводилось на территории заповедника «Кологривский лес» в смешанном малонарушенном древостое.

Материалы и методы

Объект исследований

Заповедник «Кологривский лес» расположен в северо-восточной части Костромской области, состоит из двух участков (Мантуровский и Кологривский). Общая площадь заповедника составляет 58939.6 га. В 2020 г. заповедник стал частью одноименного биосферного резервата в рамках программы ЮНЕСКО «Человек и биосфера» (https://en.unesco.org/biosphere/eu-na/kologrivsky-forest). Наибольший интерес для изучения представляет старовозрастный хвойно-широколиственный массив площадью 918 га на территории Кологривского участка, так называемое «ядро» заповедника (Коренные..., 1988). Согласно литературным данным, еловые леса «ядра» не подвергались антропогенным нарушениям на протяжении последних 350–400 лет (Иванов и др., 2012; Хорошев и др., 2013). В древесном ярусе этих лесов участвуют *Picea abies* (L.) Karst., *Abies sibirica* Ledeb., *Tilia cordata* Mill., *Ulmus glabra* Huds., *Acer platanoides* L., *Betula pubescens* Ehrh. Древостои разновозрастные и многоярусные. В 2021 г. леса «ядра» заповедника были значительно повреждены шквальным ветром (Лебедев и Чистяков, 2021 b); тем не менее, некоторые фрагменты малонарушенных южнотаежных ельников сохранились. Настоящая работа проводилась на постоянной пробной площади (ППП), слабо затронутой последствиями катастрофического ветровала.

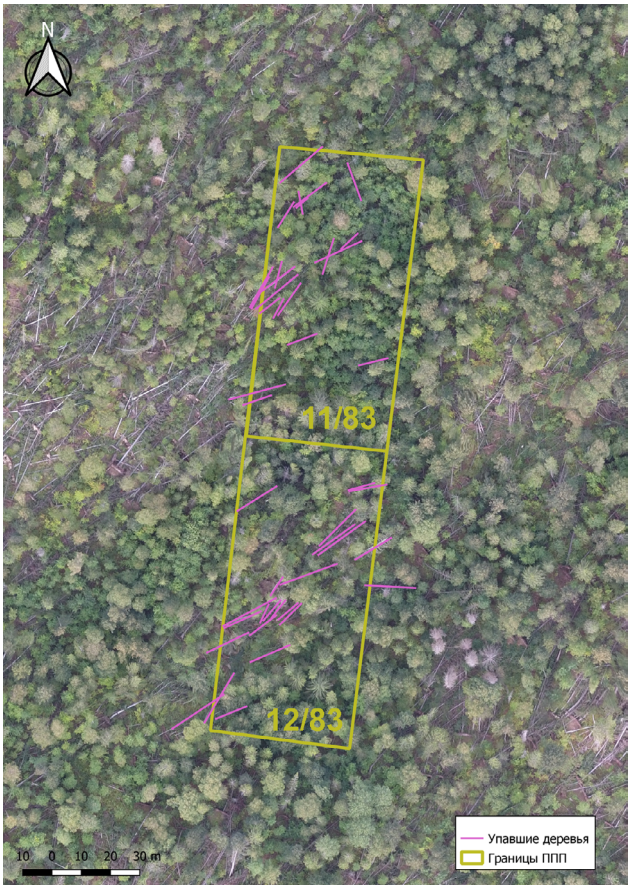

Рис. 1. Постоянная пробная площадь на ортофотоплане.

Обследованная ППП размером 200×50 м (1 га) заложена в 1983 г., повторный перечет проведен в 2017 г. Площадь состоит из двух примыкающих субплощадей по 0.5 га (№№ 11/83 и 12/83 по нумерации, принятой в заповеднике, Рис. 1). Таксационные показатели древостоев на 2017 г.

представлены в Табл. 1 согласно работе А.В. Лебедева и С.А. Чистякова (2021a). В 2017 г. зафиксирован активный распад еловых древостоев вследствие естественного выпадения крупномерных деревьев ели.

Методы сбора и анализа полевых данных

Аэрофотосъемку ППП проводили 27 и 28 августа 2021 г. квадрокоптером DJI Phantom 4 в режиме mosaic flight с высоты 336 м с 80% перекрытием фотографий (для всей территории «ядра» заповедника) и с высоты 154 м с 95% перекрытием (для ППП). Во избежание краевого эффекта при обработке данных полетные планы строили с буферной зоной. Фотограмметрическую обработку полученных изображений проводили в программе Agisoft Metashape v. 1.5 (2019), где были построены плотные облака точек (для ППП плотностью 436.9 точек/м^2, Рис. 2), и ортофотопланы (разрешением 5 и 10 см/пиксель для ППП и всей территории «ядра» соответственно).

Поскольку опубликованные данные о состоянии древостоев на ППП были собраны до катастрофического ветровала, сначала проводили оценку ветровальных повреждений. Для этого по ортофотоплану выполняли ручную векторизацию всех визуально различимых стволов упавших деревьев. Также анализировали гистограмму распределения значений высот пикселей в цифровой модели высот.

Для детектирования вершин деревьев строили модель высот древесного полога (Canopy Height Model). Для этого облако точек обрабатывали в среде R (R Core Team, 2021) при помощи пакетов lidR v. 3.1.2 (Roussel et al., 2020) и rLiDAR (Silva et al., 2018). Эти пакеты с открытым исходным кодом предназначены для обработки данных воздушного лазерного сканирования (LiDAR) и фотограмметрических облаков точек, а также производных из них моделей высот. Модель высот древесного полога строили на основе фотограмметрического облака точек при помощи функций пакета lidR. Сначала выделяли точки класса «земная поверхность» по алгоритму cloth simulation filtering (Zhang et al., 2016b), реализованному в функции classify_ground(). Затем при помощи функции normalize_height() выполняли нормализацию облака точек по уровню земной поверхности по алгоритму tin (triangular interpolation network). После этого строили модель высот древесного полога по алгоритму pit-free (Khosravipour et al., 2014), используя функцию grid_canopy(). В результате получена модель высот древесного полога с пространственным разрешением 40 см/пиксель. По этой модели высот автоматически детектировали вершины деревьев при помощи алгоритма, основанного на использовании скользящего окна, реализованного в функции FindTreesCHM() пакета rLiDAR. Тестировали разные сочетания размера скользящего окна (аргумент fws) и минимальной высоты дерева (аргумент minht).

Для выделения отдельных деревьев по ортофотоплану использовали готовую нейронную сеть, доступную в библиотеке DeepForest, реализованной в среде Python (Weinstein et al., 2020). Эта

Табл. 1. Таксационные показатели древостоев на исследованной постоянной пробной площади по состоянию на 2017 г. (по: Лебедев и Чистяков, 2021a, с изменениями).

Субплощадь	Элемент леса	Возраст, лет	Средний диаметр, см	Средняя высота, м	Число деревьев, шт./га	Сумма площадей сечений, м^2/га	Запас, м^3/га
11/83	Ель	130	25.7	23.4	200	11.4	145
	Береза	135	40.6	28.2	48	6.2	81
	Липа	115	32.3	22.1	224	18.4	191
	Пихта	100	12.6	14.4	8	0.1	1
	Клен	30	10.8	12.6	22	0.2	1
	Ива	100	35.7	21.8	8	0.8	8
	Итого	**130**			**530**	**37.1**	**427**
12/83	Ель	125	30.2	26.1	142	10.2	136
	Береза	135	29.7	25.1	26	1.8	19
	Липа	115	29.5	21.2	152	10.4	103
	Клен	20	8.0	11.8	4	0	0
	Итого	**120**			**324**	**22.4**	**258**

нейронная сеть построена на основе полуконтролируемого обучения. Такая модель подразумевает ввод небольших объемов размеченных данных для дополнения наборов данных, не имеющих меток. Размеченные данные служат для запуска системы и способны значительно повысить скорость и точность обучения. Используемая в DeepForest модель обучена разработчиками на описаниях 24 лесных участков Национальной сети экологического мониторинга США. Данные включали 434551 дерево, найденное автоматически, и 2848 деревьев, размеченных вручную (Weinstein et al., 2019). В нашем исследовании для детектирования деревьев тестировали разные варианты размера плитки (tile): 200, 400, 600 и 800 пикселей, как это рекомендовано разработчиками. Анализ проводили по ортофотоплану разрешением 10 см/пиксель.

Для оценки качества результатов автоматического детектирования рассчитывали следующие показатели: TP (true positive) – число корректно детектированных алгоритмом деревьев; FP (false positive) – число ложных срабатываний алгоритма, когда дерево либо выделено автоматически, но отсутствует на местности, либо найденная вершина относится к уже детектированному дереву; FN (false negative) – число пропущенных деревьев, которые существуют на местности, но не детектированы автоматически (Рис. 3).

Оценку числа корректно детектированных деревьев (TP) и ложных срабатываний (FP) выполняли на основе визуального анализа ортофотоплана. Поскольку подробные данные перечета ППП 2017 г. отсутствовали, для оценки числа пропущенных алгоритмом деревьев (FN) в среде QGIS (QGIS Development Team, 2019) вручную детектировали все деревья по цифровой модели высот и ортофотоплану. Для этого у каждого визуально распознаваемого по ортофотоплану дерева экспертно определяли границы кроны, затем, руководствуясь моделью высот, для каждого дерева отмечали вершину. После этого рассчитывали FN как разницу между числом детектированных вручную деревьев и числом вершин, корректно детектированных автоматически. Оценку выполняли только для древостоя (высота > 20 м), поскольку надежное визуальное детектирование деревьев подроста и подлеска в окнах часто не представляется возможным. Для всех деревьев (TP, FP и FN) на основе экспертной оценки по ортофотоплану указывали принадлежность к лиственным или хвойным. Затем рассчитывали оценки, принятые для анализа качества автоматического детектирования (Goutte & Gaussier, 2005; Li et al., 2012; Sokolova et al., 2008).

Оценка *p* (precision) показывает качество обнаружения деревьев и рассчитывается как доля корректно детектированных алгоритмом деревьев относительно числа всех найденных автоматически:

$$p = \frac{TP}{TP + FP}$$

Оценка *r* (recall) характеризует полноту обнаружения деревьев алгоритмом и рассчитывается как доля корректно найденных автоматически деревьев относительно числа детектированных вручную деревьев (т.е. имеющихся на местности):

$$r = \frac{TP}{TP + FN}$$

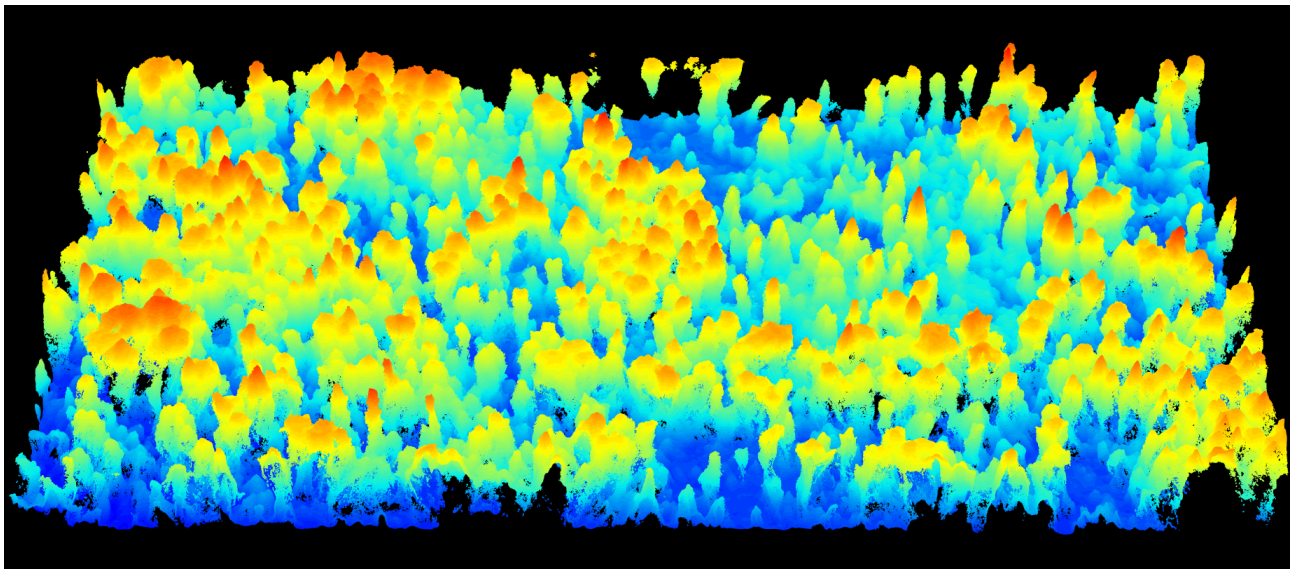

Рис. 2. Необработанное фотограмметрическое облако точек в среде R.

Рис. 3. Корректно детектированные деревья (TP), ложные срабатывания (FP) и пропущенные алгоритмом (FN) деревья на фрагменте ортофотоплана.

Оценка *F* (F-score) характеризует качество результатов в целом, с учетом *r* и *p*, и рассчитывается по формуле:

$$F = \frac{2 * r * p}{r + p}$$

Чем больше деревьев пропущено алгоритмом, тем меньше величина *r*; низкие значения *p* указывают на большое число ложных срабатываний. Значение *F* будет высоким при высоких значениях *r* и *p*, т.е. когда автоматически найдено большинство имеющихся на местности (в данном случае детектированных вручную) деревьев, а число пропущенных деревьев и ложных срабатываний невелико. Значения оценок могут варьировать от 0 до 1; в литературе качество детектирования описывается как высокое, если *r, p* и *F* > 0.8 (Иванова и др., 2021; Chen et al., 2022; Gonçalves et al., 2022; Silva et al., 2016 Chen et al., 2022; Gonçalves et al., 2022).

По результатам обработки цифровой модели высот оценки рассчитывали для разных вариантов сочетаний аргументов функции FindTreesCHM(). В каждом варианте анализировали значения, полученные для всех данных, только для древостоя (> 20 м) и подроста и подлеска (< 20 м). По результатам обработки ортофотоплана при помощи нейронной сети оценки рассчитывали для разных вариантов размера плитки, но только для древостоя.

Результаты и обсуждение

Визуальный анализ ортофотоплана и модели высот показал, что древесная растительность на исследуемой ППП имеет неоднородную вертикальную структуру (Рис. 1, 4, 5). Известно, что модель высот характеризует только верхний ее ярус, поэтому по характеру распределения значений высот пикселей можно выявить наличие неоднородностей и разрывов в пологе (Портнов и др., 2021). На полученной нами гистограмме распределения значений высот пикселей в цифровой модели высот древесного полога хорошо заметны 2 пика (Рис. 4). Левый соответствует растительности в «окнах» в пологе, правый – группам наиболее крупномерных деревьев, образующих древостой. При этом число пикселей, соответствующих крупномерным деревьям, невелико, а форма распределения отличается

от характерной для сомкнутых лесов и более близка к участкам, где сомкнутый древостой отсутствует (Портнов и др., 2021; Ivanova and Shashkov, 2022).

Также выяснено, что на момент проведения дистанционных исследований на субплощади 11/83 сомкнутый древостой отсутствовал, сохранились только отдельные крупномерные деревья. Древесная растительность в основном была представлена подростом и подлеском, при этом на ортофотоплане в местах, где древостой отсутствовал, видны лишь единичные упавшие стволы. Это позволяет предположить, что распад древостоя произошел до катастрофического ветровала вследствие естественного изреживания, что согласуется с результатами перечета 2017 г. Давно упавшие деревья могут быть скрыты ярусами подроста и подлеска и, следовательно, не видны на ортофотоплане. Выпавшие в результате катастрофического ветровала деревья, детектированные на этой субплощади, в основном упали из соседних с ней участков (Рис. 1). На субплощади 12/83 число крупномерных деревьев больше по сравнению с субплощадью 11/83, древесный ярус не сомкнут. Хорошо различима полоса из упавших деревьев, ориентированная с юго-запада на северо-восток; по всей видимости, эти деревья были повалены шквальным ветром в 2021 г. Также имеются небольшие «окна», в которых по ортофотоплану неразличимы упавшие деревья. По всей видимости, они образовались до катастрофического ветровала в результате выпадения отдельных крупномерных деревьев. Таким образом, древесная растительность исследованного участка неоднородна и сформировалась как в результате длительной естественной динамики древостоев, так и из-за массового ветровала.

В результате автоматического детектирования вершин деревьев по цифровой модели высот при разных вариантах аргументов функции FindTreesCHM() на всей ППП детектировано от 82 до 320 вершин (Рис. 5, Табл. 2). В ходе ручного детектирования деревьев верхнего яруса выделено 136 деревьев (51 хвойное и 85 лиственных). Сопоставление этих данных с ортофотопланом показало, что наиболее качественные результаты получены при использовании скользящего окна размером 5 пикселей и при минимальной высоте детектируемых деревьев 10 или 15 м. Результаты этих экспериментов использованы для количественной оценки качества детектирования.

Оценка качества результатов автоматического детектирования, выполненная для всех деревьев и отдельно по ярусам, показала высокое качество поиска *p* для обоих анализируемых сочетаний аргументов функции FindTreesCHM() (Табл. 3). Полученные данные показывают, что алгоритм в большинстве случаев корректно находил вершины деревьев. При этом качество детектирования хвойных деревьев было выше, чем лиственных.

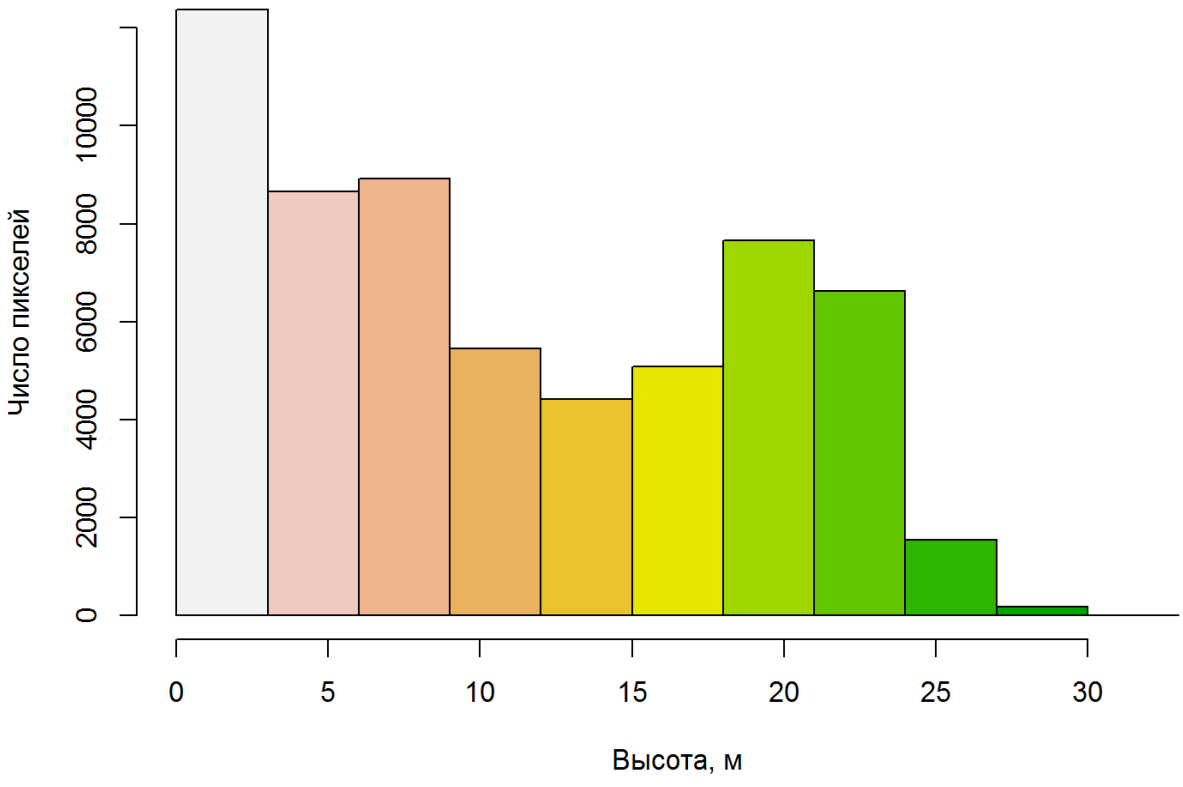

Рис. 4. Гистограмма распределения значений высот пикселей в цифровой модели высот. Цвета соответствуют легенде на рис. 5.

Табл. 2. Результаты автоматического детектирования цифровой модели высот при разных вариантах аргументов функции FindTreesCHM().

Минимальная высота дерева (minht), м	Размер скользящего окна (fws), пикселей, м	Число детектированных вершин деревьев, шт.	
		Всего	Из них высотой > 20 м
10	3 (1.2)	320	217
10	5 (2)	174	134
15	5 (2)	134	125
20	5 (2)	82	82

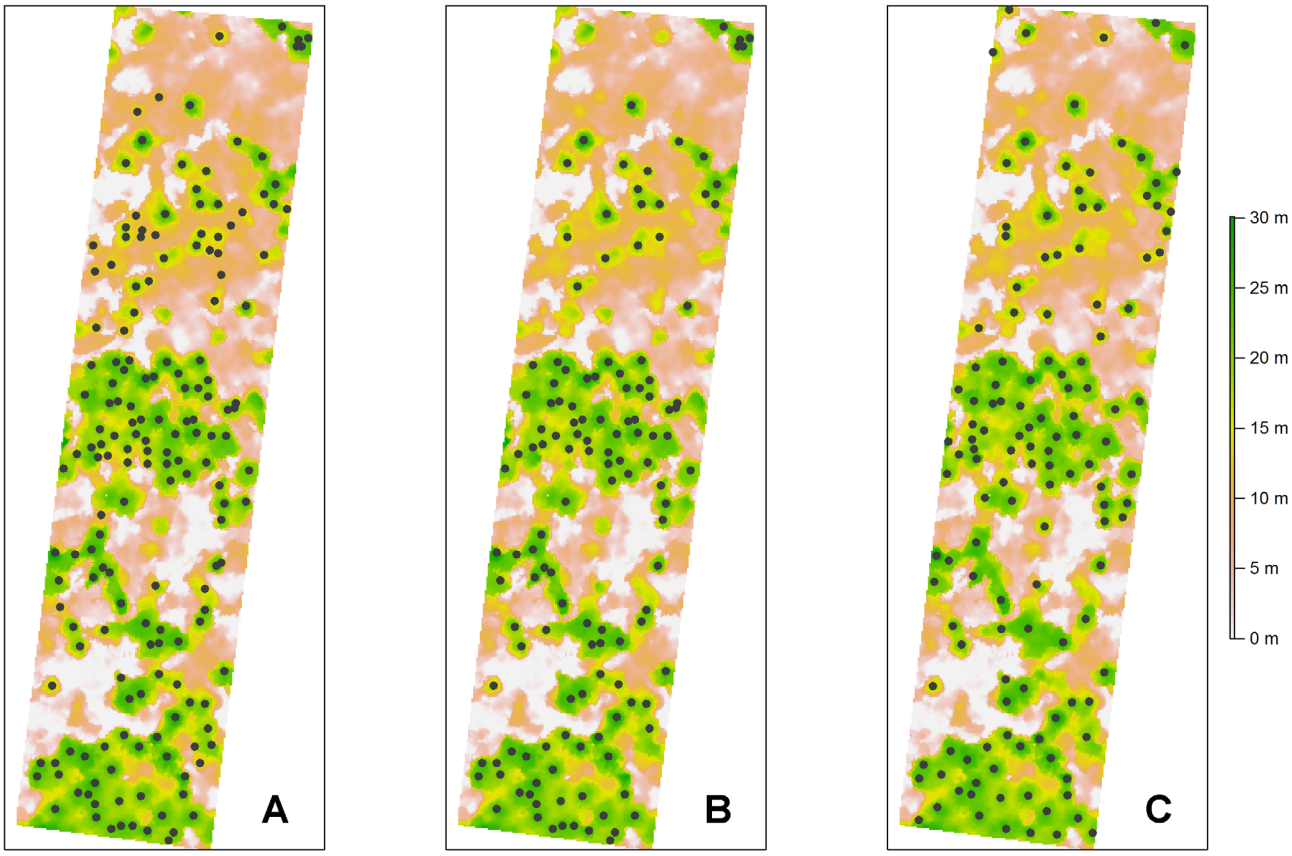

Рис. 5. Результаты автоматического детектирования вершин деревьев по цифровой модели высот при разных значениях аргументов функции FindTreesCHM(): **A** – при minht = 10, fws = 5; **B** – при minht = 15, fws = 5; **C** – результаты ручного детектирования деревьев.

Оценка полноты обнаружения *r* рассчитана только для древостоя. Выяснено, что полнота обнаружения лиственных деревьев была довольно высокой и сопоставимой в обоих экспериментах, при этом значение оценки *r* было выше *p*. Это свидетельствует, что при детектировании лиственных деревьев алгоритм чаще находил ложные вершины, чем пропускал деревья. Для хвойных деревьев при minht = 10 обе оценки были высокими, значение *r* было чуть ниже *p*. При minht = 15 оценка *r* была низкой (существенно ниже, чем *p*). Эти результаты показывают, что в случае хвойных алгоритм чаще пропускал деревья, чем находил ложные вершины.

Значения оценки *F*, характеризующей качество детектирования в целом, были довольно высокими. Наибольшее значение (0.95) получено для хвойных деревьев при minht = 10, наименьшее (0.78) – для лиственных при minht = 10. В обоих экспериментах значения *F* для хвойных было выше по сравнению с лиственными.

В результате детектирования деревьев по ортофотоплану при помощи нейросетевого алгоритма DeepForest наилучшие результаты получены при размерах плиток 400 и 600 пикселей. При размере плиток до 400 пикселей моделью выделялись слишком дробные объекты, за счет чего наиболее крупные кроны распознавались как совокупности нескольких мелких. При размере плиток более 800 пикселей, напротив, кроны нескольких рядом стоящих деревьев детектировались как одно дерево.

При использовании плитки размером 400 пикселей детектировано 381 дерево, 600 пикселей – 218 деревьев. Обнаруженные деревья относились как к древостою, так и к подросту и подлеску, поэтому их число выше, чем полученное при детектировании по модели высот.

Оценку качества результатов работы нейронной сети выполняли только для древостоя. Отмечено, что по сравнению с цифровой моделью высот качество детектирования деревьев было выше (Табл. 4); при этом хвойные деревья, как правило, также детектированы лучше лиственных. Во всех случаях значение оценки *p* было выше *r,* т.е. нейронная сеть чаще пропускала деревья, чем находила ложные (в данном случае объединяла несколько деревьев в одну крону). Значения оценки *F*, характеризующей качество детектирования в целом, были высокими. Согласно этой оценке, в первом эксперименте качество обнаружения хвойных и лиственных деревьев было одинаковым, во втором более качественными были результаты, полученные для хвойных.

В целом можно заключить, что при помощи готовых алгоритмов на исследованном участке смешанного леса удалось с высокой точностью выявить большинство деревьев в древостое. В наших предыдущих исследованиях в сосновых и сосново-еловых лесах на территории Приокско-Террасного биосферного заповедника было показано, что участие в древостое деревьев нескольких видов, выраженная ярусность или разрывы в пологе леса могут снижать качество детектирования деревьев по цифровым моделям высот (Иванова и др., 2021). В данном исследовании качество детектирования в целом было высоким, несмотря на полидоминантность и неоднородную вертикальную структуру древесной растительности. Такой результат, по всей видимости, объясняется тем, что на исследованном участке отсутствует сомкнутый полог, взрослые деревья расположены одиночно либо группами. При этом даже в случае группового расположения кроны отдельных деревьев хорошо выделялись на модели высот и на ортофотоплане. По всей видимости, низкая плотность деревьев стала основным фактором для их успешного детектирования. Этот вывод подтверждается литературными данными, согласно которым качество сегментации деревьев в разреженных древостоях выше, чем в сомкнутых (Медведев и др., 2020; Alonzo et al., 2014,; 2018; Kolarik et al., 2020).

Важно также отметить, что методы сегментации деревьев на основе глубокого обучения продолжают активно развиваться. Так, в работе M. Onishi & T. Ise (2021) не только успешно сегментированы кроны деревьев в смешанных сомкнутых лиственных лесах, но и с высокой точностью выделено 9 классов деревьев. Дальнейшее развитие этих методов позволит получать более точные оценки, описывающие структуру древостоев, и прогнозировать их динамику.

Полученные нами результаты также показали более высокое качество детектирования хвойных деревьев по сравнению с лиственными. Все представленные на ППП хвойные деревья (в основном ель, с небольшим участием пихты) имели хорошо выраженную вершину. Крупные лиственные деревья (береза и липа), напротив, имели шарообразные кроны, в пределах которых алгоритм часто находил несколько вершин. В целом такой результат является ожидаемым и согласуется с имеющимися в литературе данными (Иванова и др., 2020; Alonzo et al., 2018; Bennett et al., 2020).

Существенный интерес для дальнейших исследований представляет разработка методики более полного учета подроста. Очевидно, что для решения этой задачи на основе модели высот необходимо использовать скользящее окно меньшего размера, чем для детектирования взрослых деревьев; кроме того, вероятно, потребуются модели высот древесного полога большего разрешения. Итоги предварительных экспериментов (собств. данные) показали, что по модели высот разрешением 40 см/пиксель удается детектировать большое число вершин деревьев, образующих ярус подроста. В случае использования нейронной сети DeepForest перспективным способом улучшения результатов является обучение модели на данных из соседних с ППП участков. Такой подход рекомендован разработчиками для лучшего учета локальных особенностей древостоев (Weinstein et al., 2020). В любом случае оценка качества этих результатов не представляется возможной без данных наземных исследований.

Нами также показано, что полученные автоматически оценки средних высот деревьев хорошо согласуются с результатами наземных измерений (Табл. 5), однако провести детальное сравнение на уровне отдельных деревьев невозможно ввиду отсутствия более подробных данных. Тем не менее, наши результаты согласуются с полученными на других объектах выводами о хорошей сходимости этих оценок (Bennet et al., 2020; Birdal et al., 2017; Panagiotidis et al., 2017). В то же время необходимо отметить, что автоматические оцен-

Табл. 3. Оценка качества результатов автоматического детектирования вершин деревьев на постоянной пробной площади по цифровой модели высот.

Аргументы функции FindTreesCHM()	Детектированные деревья	Все детектированные деревья			Деревья высотой < 20 м			Деревья высотой > 20 м					
		TP	FP	*p*	TP	FP	*p*	TP	FP	FN	*p*	*r*	*F*
minht = 10 *fws* = 5	Хвойные	56	0	1	10	0	1	46	0	5	1	0.90	0.95
	Лиственные	94	24	0.80	26	4	0.87	68	20	17	0.77	0.80	0.78
	Всего	150	24	0.86	36	4	0.90	114	20	22	0.85	0.84	0.84
minht = 15 *fws* = 5	Хвойные	39	0	1	2	0	1	37	0	14	1	0.72	0.84
	Лиственные	76	19	0.80	6	1	0.86	70	18	15	0.79	0.82	0.80
	Всего	115	19	0.86	8	1	0.89	107	18	29	0.86	0.79	0.82

Табл. 4. Оценка качества результатов детектирования деревьев верхнего яруса на постоянной пробной площади при помощи нейронной сети.

Размер плитки, пикселей	Детектированные деревья	TP	FP	FN	*p*	*r*	*F*
400	Хвойные	45	0	6	1	0.88	0.94
	Лиственные	76	3	6	0.96	0.93	0.94
	Всего	121	3	12	0.98	0.91	0.94
600	Хвойные	45	2	4	0.96	0.92	0.94
	Лиственные	58	5	22	0.92	0.73	0.81
	Всего	103	7	26	0.94	0.80	0.86

Табл. 5. Сопоставление высот деревьев по данным наземных измерений 2017 г. и оценок, полученных по данным аэрофотосъемки 2021 г. SD – стандартное отклонение, min – минимальная высота, max – максимальная высота.

Деревья	Средняя высота по наземным измерениям 2017 г., м	Высота по модели высот 2021 г., средняя ± SD (min, max), м
	Все деревья	
Хвойные	21.3	23.5 ± 3.7 (14.5, 30.0)
Лиственные	20.4	21.4 ± 4.0 (11.1, 29.0)
	Деревья высотой > 20 м	
Хвойные	24.8	24.9 ± 2.5 (20.0, 30.0)
Лиственные	24.1	23.4 ± 1.8 (20.2, 29.0)

ки высот могут иметь погрешности, связанные с артефактами обработки фотограмметрического облака при выделении точек класса «земная поверхность». Кроме того, в ряде работ показано, что наземные измерения высот, особенно крупных лиственных деревьев, могут иметь значительные погрешности вследствие неоднозначности определения вершины (Иванова и др., 2021; Alonzo et al., 2018; Bennet et al., 2020).

Заключение

Данная работа представляет результаты исследования структуры древостоев на основе ортофотопланов и фотограмметрических моделей высот древесного полога – нового и активно развивающегося в России направления. Были исследованы малонарушенные южно-таежные ельники со сложной структурой древостоя.

Полученные данные показали, что, несмотря на присутствие деревьев нескольких видов и пространственную неоднородность древостоя, готовые алгоритмы для обработки данных аэрофотосъемки позволяют с уверенностью выявить большинство деревьев в пологе леса. Качество результатов детектирования по ортофотоплану при помощи нейронной сети было выше качества детектирования по модели высот с использованием алгоритма, основанного на методе скользящего окна. В обоих случаях качество обнаружения хвойных деревьев, как правило, было несколько выше по сравнению с лиственными. Средние высоты, оцененные по цифровым моделям высот, хорошо согласовывались с результатами наземных измерений. Для оценки качества детектирования подроста требуются дополнительные наземные обследования.

В целом полученные результаты подтверждают, что дистанционные данные, собираемые при помощи БПЛА, позволяют получить реалистичные оценки характеристик древостоев. Можно сделать вывод о перспективности использования этих методов в практике лесного хозяйства для проведения плановых лесотаксационных работ, а также для оперативного получения данных о состоянии древостоев после катастрофических явлений. Использование данного подхода особенно актуально для труднодоступных территорий, где сложно организовать наземные исследования.

ORCID

Н.В. Иванова 0000-0003-4199-5924
А.В. Лебедев 0000-0002-8939-942X
М.П. Шашков 0000-0002-1328-8758

Финансирование

Работа выполнена в рамках бюджетных тем ИМПБ РАН – филиал ИПМ им. М.В. Келдыша РАН и заповедника «Кологривский лес».

Список литературы

Иванов, А.Н., Буторина, Е.А., Балдина, Е.А., 2012. Многолетняя динамика коренных южно-таежных ельников в заповеднике Кологривский лес. *Вестник Московского университета. Серия 5. География* **3**, 74–79.

Иванова, Н.В., Шашков, М.П., Шанин, В.Н., Грабарник, П.Я., 2020. Оценка качества автоматического детектирования деревьев по материалам аэрофотосъемки с помощью квадрокоптера. *Доклады международной конференции «Математическая биология и биоинформатика». Лахно, В.Д. (ред.). Т. 8.* ИМПБ РАН, Пущино, Россия, статья № e36. http://www.doi.org/10.17537/icmbb20.31

Иванова, Н.В., Шашков, М.П., Шанин, В.Н., 2021. Исследование структуры древостоев сосновых лесов Приокско-Террасного биосферного заповедника (Россия) по материалам аэрофотосъемки с квадрокоптера. *Nature Conservation Research. Заповедная наука* **6** (4), 1–14. http://www.doi.org/10.24189/ncr.2021.042

Коренные темнохвойные леса южной тайги (резерват «Кологривский лес»), 1988. Абатуров, Ю.Д., Письмеров, А.В., Орлов, А.Я. и др. (ред.). Наука, Москва, СССР, 220 с.

Лебедев, А.В., Чистяков, С.А., 2021a. Долговременные наблюдения на пробных площадях в древостоях ядра заповедника «Кологривский лес». *Материалы конференции «Вклад ООПТ в экологическую устойчивость регионов: современное состояние и перспективы.* Кологрив, Россия, 31–43.

Лебедев, А.В., Чистяков, С.А., 2021b. Оценка последствий ветровала 2021 года на территории биосферного резервата «Кологривский лес». *Материалы конференции «Вклад ООПТ в экологическую устойчивость регионов: современное состояние и перспективы.* Кологрив, Россия, 71–77.

Медведев, А.А., Тельнова, Н.О., Кудиков, А.В., Алексеенко, Н.А., 2020. Анализ и картографирование структурных параметров редкостойных северотаежных лесов на основе фотограмметрических облаков точек. *Современные проблемы дистанционного зондирования Земли из космоса* **17** (1), 150–163. http://www.doi.org/10.21046/2070-7401-2020-17-1-150-163

Портнов, А.М., Быховец, С.С., Дин, Е.С., Иванова, Н.В., Фролов, П.В., Шанин, В.Н., Шашков, М.П., 2021. Количественная оценка

размеров окон в пологе старовозрастного широколиственного леса наземными и дистанционными методами. *Материалы Седьмой конференции «Математическое моделирование в экологии» ЭкоМатМод-2021.* Пущино, Россия, 99–102.

Хорошев, А.В., Немчинова, А.В., Кощеева, А.С., Иванова, Н.В., Петухов, И.Н., Терентьева, Е.В., 2013. Ландшафтные и сукцессионные факторы соотношения неморальных и бореальных свойств травяного яруса в заповеднике Кологривский лес. *Вестник Московского университета. Серия 5. География* **5**, 11–18.

Agisoft LLC,. 2019. Agisoft Metashape (Version 1.5). Software. URL: https://www.agisoft.com/

Alonzo, M., Bookhagen, B., Roberts, D.A., 2014. Urban tree species mapping using hyperspectral and LiDAR data fusion. *Remote Sensing of Environment* **148**, 70–83 http://www.doi.org/10.1016/j.rse.2014.03.018

Alonzo, M., Andersen, H.E., Morton, D.C., Cook, B.D., 2018. Quantifying boreal forest structure and composition using UAV structure from motion. *Forests* **9** (3), 119. http://www.doi.org/10.3390/f9030119

Anderson, K., Gaston, K.J., 2013. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment* **11** (3), 138–146. http://www.doi.org/10.1890/120150

Bennett, G., Hardy, A., Bunting, P., Morgan, P., Fricker, A., 2020. A transferable and effective method for monitoring continuous cover forestry at the individual tree level using UAVs. *Remote Sensing* **12** (13), 2115. http://www.doi.org/10.3390/rs12132115

Birdal, A.C., Avdan, U., Türk, T., 2017. Estimating tree heights with images from an unmanned aerial vehicle. *Geomatics, Natural Hazards and Risk* **8** (2), 1144–1156. http://www.doi.org/10.1080/19475705.2017.1300608

Chen, Q., Gao, T., Zhu, J., Wu, F., Li, X., Lu, D., Yu, F., 2022. Individual tree segmentation and tree height estimation using leaf-off and leaf-on UAV-LiDAR data in dense deciduous forests *Remote Sensing* **14** (12), 2787. https://doi.org/10.3390/rs14122787

Christin, S., Hervet, É., Lecomte, N., 2019. Applications for deep learning in ecology. *Methods in Ecology and Evolution* **10**, 1632–1644. http://www.doi.org/10.1111/2041-210X.13256

Gonçalves, V.P., Ribeiro, E.A.W., Imai, N.N., 2022. Mapping areas invaded by *Pinus* sp. from geographic object-based image analysis (GEOBIA) applied on RPAS (Drone) color images. *Remote Sensing* **14** (12), 2805. https://doi.org/10.3390/rs14122805

Goutte, C., Gaussier, E., 2005. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In: Losada, D.E., Fernández-Luna, J.M. (eds.), *Advances in Information Retrieval. ECIR 2005. Lecture Notes in Computer Science, vol 3408*. Springer, Berlin – Heidelberg, 345–359. https://doi.org/10.1007/978-3-540-31865-1_25

Ivanova, N.V., Shashkov, M.P., 2022. Tree stand assessment before and after windthrow based on open-access biodiversity data and aerial photography. *Nature Conservation Research* **7** (Suppl. 1), 52–63. https://dx.doi.org/10.24189/ncr.2022.018

Khosravipour, A., Skidmore, A.K., Skidmore, M., Wang, T., Hussin, Y., 2014. Generating pit-free canopy height models from airborne LiDAR. *Photogrammetric Engineering and Remote Sensing* **9,** 863–872. http://www.doi.org/10.14358/PERS.80.9.863

Kislov, D.E., Korznikov, K.A., 2020. Automatic windthrow detection using very-high-resolution satellite imagery and deep learning. *Remote Sensing* **12** (7), 1145. http://www.doi.org/10.3390/rs12071145

Kolarik, N.E., Gaughan, A.E., Stevens, F.R., Pricope, N.G., Woodward, K., Cassidy, L., Salerno, J., Hartter, J., 2020. A multi-plot assessment of vegetation structure using a micro-unmanned aerial system (UAS) in a semi-arid savanna environment. *ISPRS Journal of Photogrammetry and Remote Sensing* **164**, 84–96. http://www.doi.org/10.1016/j.isprsjprs.2020.04.011

Krisanski, S., Taskhiri, M.S., Turner, P., 2020. Enhancing methods for under-canopy unmanned aircraft system based photogrammetry in complex forests for tree diameter measurement. *Remote Sensing* **12** (10), 1652. http://www.doi.org/10.3390/rs12101652

Lamba, A., Cassey, P., Segaran, R.J., Koh, L.P., 2019. Deep learning for environmental conservation. *Current Biology* **29**, R977–R982. http://www.doi.org/10.1016/j.cub.2019.08.016

Li, W., Guo, Q., Jakubowski, M.K., Kelly, M., 2012. A new method for segmenting individual trees from the LiDAR point cloud. *Photogrammetric*

Engineering and Remote Sensing **78** (1), 75–84. http://www.doi.org/10.14358/PERS.78.1.75

Miller, E., Dandois, J.P., Detto, M., Hall, J.S., 2017. Drones as a tool for monoculture plantation assessment in the steepland tropics. *Forests* **8** (5), 168. http://www.doi.org/10.3390/f8050168

Mohan, M., Silva, C.A., Klauberg, C., Jat, P., Catts, G. et al., 2017. Individual tree detection from Unmanned Aerial Vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. *Forests* **8** (9), 340. http://www.doi.org/10.3390/f8090340

Onishi, M., Ise, T., 2021. Explainable identification and mapping of trees using UAV RGB image and deep learning. *Scientific Reports* **11**, 903. http://www.doi.org/10.1038/s41598-020-79653-9

Otero, V., Van De Kerchove, R., Satyanarayana, B., Martínez-Espinosa, C., Fisol, M.A.B. et al., 2018. Managing mangrove forests from the sky: forest inventory using field data and unmanned aerial vehicle (UAV) imagery in the Matang Mangrove Forest Reserve, peninsular Malaysia. *Forest Ecology and Management* **411**, 35–45. http://www.doi.org/10.1016/j.foreco.2017.12.049

Pajares, G., 2015. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). *Photogrammetric Engineering and Remote Sensing* **81** (4), 281–330. http://www.doi.org/10.14358/PERS.81.4.281

Panagiotidis, D., Abdollahnejad, A., Surový, P., Chiteculo, V., 2017. Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing* **38** (8–10), 2392–2410. http://www.doi.org/10.1080/01431161.2016.1264028

Picos, J., Bastos, G., Míguez, D., Alonso, L., Armesto, J., 2020. Individual tree detection in a eucalyptus plantation using unmanned aerial vehicle (UAV)-LiDAR. *Remote Sensing* **12** (5), 885. http://www.doi.org/10.3390/rs12050885

Puliti, S., Ørka, H.O., Gobakken, T., Næsset, E., 2015. Inventory of small forest areas using an unmanned aerial system. *Remote Sensing* **7** (8), 9632–9654. http://www.doi.org/10.3390/rs70809632

QGIS Development Team, 2019. QGIS Geographic Information System. Open Source Geospatial Foundation Project. URL: http://qgis.osgeo.org

R Core Team, 2021. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL: https://www.R-project.org/

Roussel, J.-R., Auty, D., Coops, N.C., Tompalski, P., Goodbody, T.R.H. et al., 2020. lidR: An R package for analysis of airborne laser scanning (ALS) data. *Remote Sensing of Environment* **251**, 112061. http://www.doi.org/10.1016/j.rse.2020.112061

Silva, C.A., Hudak, A.T., Vierling, L.A., Loudermilk, E.L., O'Brien, J.J. et al., 2016. Imputation of individual Longleaf Pine (*Pinus palustris* Mill.) tree attributes from field and LiDAR Data. *Canadian Journal of Remote Sensing* **42** (5), 554–573. https://doi.org/10.1080/07038992.2016.1196582

Silva, C.A., Klauberg, C., Mohan, M., Bright, B.C., 2018. LiDAR analysis in R and rLiDAR for forestry applications. NRS 404/504 LiDAR Remote Sensing for Environmental Monitoring. University of Idaho, Moscow, Idaho, USA, 90 p.

Sokolova, M., Japkowicz, N., Szpakowicz, S., 2008. Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. *Advances in Artificial Intelligence* **4304**, 1015–1021. http://dx.doi.org/10.1007/11941439_114

Weinstein, B.G., Marconi, S., Bohlman, S., Zare, A., White, E., 2019. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing* **11** (11), 1309. http://www.doi.org/10.3390/rs11111309

Weinstein, B.G., Marconi, S., Aubry-Kientz, M., Vincent, G., Senyondo, H., White, E.P., 2020. DeepForest: a Python package for RGB deep learning tree crown delineation. *Methods in Ecology and Evolution* **11**, 1743–1751. http://www.doi.org/10.1111/2041-210X.13472

Weinstein, B.G., Marconi, S., Bohlman, S., Zare, A., White, E., 2019. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing* **11** (11), 1309. http://www.doi.org/10.3390/rs11111309

Zhang, J., Hu, J., Lian, J., Fan, Z., Ouyang, X., YeW., 2016a. Seeing the forest from drones: testing the potential of lightweight drones as a tool for long-term forest monitoring. *Biological Conservation* **198**, 60–69. http://www.doi.org/10.1016/j.biocon.2016.03.027

Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G., 2016b. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing* **8** (6), 501. http://www.doi.org/10.3390/rs8060501

Funding

The work was carried out within the framework of the State Tasks for Institute of Mathematical Problems of Biology, Keldysh Institute of Applied Mathematics, Russian Academy of Sciences and the Kologrivsky Forest Nature Reserve.

References

Agisoft LLC,. 2019. Agisoft Metashape (Version 1.5). Software. URL: https://www.agisoft.com/

Alonzo, M., Bookhagen, B., Roberts, D.A., 2014. Urban tree species mapping using hyperspectral and LiDAR data fusion. *Remote Sensing of Environment* **148**, 70–83 http://www.doi.org/10.1016/j.rse.2014.03.018

Alonzo, M., Andersen, H.E., Morton, D.C., Cook, B.D., 2018. Quantifying boreal forest structure and composition using UAV structure from motion. *Forests* **9** (3), 119. http://www.doi.org/10.3390/f9030119

Anderson, K., Gaston, K.J., 2013. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment* **11** (3), 138–146. http://www.doi.org/10.1890/120150

Bennett, G., Hardy, A., Bunting, P., Morgan, P., Fricker, A., 2020. A transferable and effective method for monitoring continuous cover forestry at the individual tree level using UAVs. *Remote Sensing* **12** (13), 2115. http://www.doi.org/10.3390/rs12132115

Birdal, A.C., Avdan, U., Türk, T., 2017. Estimating tree heights with images from an unmanned aerial vehicle. *Geomatics, Natural Hazards and Risk* **8** (2), 1144–1156. http://www.doi.org/10.1080/19475705.2017.1300608

Chen, Q., Gao, T., Zhu, J., Wu, F., Li, X., Lu, D., Yu, F., 2022. Individual tree segmentation and tree height estimation using leaf-off and leaf-on UAV-LiDAR data in dense deciduous forests *Remote Sensing* **14** (12), 2787. https://doi.org/10.3390/rs14122787

Christin, S., Hervet, É., Lecomte, N., 2019. Applications for deep learning in ecology. *Methods in Ecology and Evolution* **10**, 1632–1644. http://www.doi.org/10.1111/2041-210X.13256

Gonçalves, V.P., Ribeiro, E.A.W., Imai, N.N., 2022. Mapping areas invaded by *Pinus* sp. from geographic object-based image analysis (GEOBIA) applied on RPAS (Drone) color images. *Remote Sensing* **14** (12), 2805. https://doi.org/10.3390/rs14122805

Goutte, C., Gaussier, E., 2005. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In: Losada, D.E., Fernández-Luna, J.M. (eds.), *Advances in Information Retrieval. ECIR 2005. Lecture Notes in Computer Science, vol 3408*. Springer, Berlin – Heidelberg, 345–359. https://doi.org/10.1007/978-3-540-31865-1_25

Ivanova, N.V., Shashkov, M.P., 2022. Tree stand assessment before and after windthrow based on open-access biodiversity data and aerial photography. *Nature Conservation Research* **7** (Suppl. 1), 52–63. https://dx.doi.org/10.24189/ncr.2022.018

Ivanov, A.N., Butorina, E.A., Baldina, E.A., 2012. Mnogoletnyaya dinamika korennykh yuzhno-taezhnykh el'nikov v zapovednike Kologrivskii les [Long-term dynamics of primary spruce forests (southern taiga) in the Kologriv Forest Nature Reserve]. *Vestnik Moskovskogo Universiteta. Seria 5. Geografia [Moscow University Bulletin. Series 5. Geography]* **3**, 74–79. (In Russian).

Ivanova, N.V., Shashkov, M.P., Shanin, V.N., Grabarnik, P.Ya., 2020. Otsenka kachestva avtomaticheskogo detektirovaniya derev'ev po materialam aerofotos'emki s pomoshch'iu kvadrokoptera [Quality assessment of automatic tree detection based on aerial photography using a quadcopter]. *Doklady mezhdunarodnoi konferentsii «Matematicheskaya biologiya i bioinformatika». Lakhno, V.D. (ed.). T. 8 [Proceedings of the International Conference "Mathematical Biology and Bioinformatics". Lakhno, V.D. (ed.). Vol. 8].* Institute of Mathematical Problems of Biology RAS, Pushchino, Russia, proceeding no. e36. (In Russian). http://www.doi.org/10.17537/icmbb20.31

Ivanova, N.V., Shashkov, M.P., Shanin, V.N., 2021. Issledovanie struktury drevostoev sosnovykh lesov Prioksko-terrasnogo biosfernogo zapovednika (Rossiya) po materialam aerofotos'emki s kvadrokoptera [Study of pine forest stand structure in the Priosko-Terrasny State Nature Biosphere Reserve (Russia) based on aerial photography by quadcopter]. *Nature Conservation Research. Zapovednaya nauka. [Nature Conservation Research]* **6** (4), 1–14. (In Russian). http://www.doi.org/10.24189/ncr.2021.042

Khoroshev, A.V., Nemchinova, A.V., Koshcheeva, A.S., Ivanova, N.V., Petukhov, I.N., Terentieva, E.V., 2013. Landshaftnye i suktsessionnye faktory sootnosheniya nemoral'nykh i boreal'nykh svoistv travyanogo yarusa v zapovednike Kologrivskii les [Landscape and succession factors determining the balance between nemoral and boreal features of the grass layer in the Kologriv Forest Reserve]. *Vestnik Moskovskogo Universiteta. Seria 5. Geografia [Moscow University Bulletin. Series 5. Geography]* **5**, 11–18. (In Russian).

Khosravipour, A., Skidmore, A.K., Skidmore, M., Wang, T., Hussin, Y., 2014. Generating pit-free canopy height models from airborne LiDAR. *Photogrammetric Engineering and Remote Sensing* **9,** 863–872. http://www.doi.org/10.14358/PERS.80.9.863

Kislov, D.E., Korznikov, K.A., 2020. Automatic windthrow detection using very-high-resolution satellite imagery and deep learning. *Remote Sensing* **12** (7), 1145. http://www.doi.org/10.3390/rs12071145

Kolarik, N.E., Gaughan, A.E., Stevens, F.R., Pricope, N.G., Woodward, K., Cassidy, L., Salerno, J., Hartter, J., 2020. A multi-plot assessment of vegetation structure using a micro-unmanned aerial system (UAS) in a semi-arid savanna environment. *ISPRS Journal of Photogrammetry and Remote Sensing* **164**, 84–96. http://www.doi.org/10.1016/j.isprsjprs.2020.04.011

Korennye temnokhvoinye lesa yuzhnoi taigi (rezervat «Kologrivskii les») [Old dark coniferous forests of the southern taiga ("Kologrivsky forest" reserve)], 1988. Abaturov Yu.D., Pis'merov A.V., Orlov, A.Ya. et al. (eds.). Nauka, Moscow, Russia, 220 c. (In Russian).

Krisanski, S., Taskhiri, M.S., Turner, P., 2020. Enhancing methods for under-canopy unmanned aircraft system based photogrammetry in complex forests for tree diameter measurement. *Remote Sensing* **12** (10), 1652. http://www.doi.org/10.3390/rs12101652

Lamba, A., Cassey, P., Segaran, R.J., Koh, L.P., 2019. Deep learning for environmental conservation. *Current Biology* **29**, R977–R982. http://www.doi.org/10.1016/j.cub.2019.08.016

Lebedev, A.V., Chistyakov, S.A., 2021a. Dolgovremennye nabliudeniya na probnykh ploshchadyakh v drevostoyakh yadra zapovednika «Kologrivskii les» [Long-term observations on permanent sample plots in stands of the Kologrivski Forest Nature Reserve]. *Materialy konferentsii «Vklad OOPT v ekologicheskuiu ustoichivost' regionov: sovremennoe sostoianie i perspektivy [Proccedings of the Conference "Contribution of Protected Areas to the Ecological Sustainability of Regions: Current State and Prospects].* Kologriv, Russia, 31–43. (In Russian).

Lebedev, A.V., Chistyakov, S.A., 2021b. Otsenka posledstvii vetrovala 2021 goda na territorii biosfernogo rezervata «Kologrivskii les» [Assessment of the impact of the windfall timber in 2021 on the Kologrvski Forest Biosphere Reserve]. *Materialy konferentsii «Vklad OOPT v ekologicheskuiu ustoichivost' regionov: sovremennoe sostoianie i perspektivy [Proccedings of the Conference "Contribution of Protected Areas to the Ecological Sustainability of Regions: Current State and Prospects].* Kologriv, Russia, 71–77. (In Russian).

Li, W., Guo, Q., Jakubowski, M.K., Kelly, M., 2012. A new method for segmenting individual trees from the LiDAR point cloud. *Photogrammetric Engineering and Remote Sensing* **78** (1), 75–84. http://www.doi.org/10.14358/PERS.78.1.75

Medvedev, A.A., Telnova, N.O., Kudikov, A.V., Alekseenko, N.A., 2020. Analiz i kartografirovanie strukturnykh parametrov redkostoinykh severotaezhnykh lesov na osnove fotogrammetricheskikh oblakov tochek [Use of photogrammetric point clouds for the analysis and mapping of structural variables in sparse northern boreal forests]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa [Current Problems in Remote Sensing of the Earth from Space]* **17** (1), 150–163. (In Russian). http://www.doi.org/10.21046/2070-7401-2020-17-1-150-163

Miller, E., Dandois, J.P., Detto, M., Hall, J.S., 2017. Drones as a tool for monoculture plantation assessment in the steepland tropics. *Forests* **8** (5), 168. http://www.doi.org/10.3390/f8050168

Mohan, M., Silva, C.A., Klauberg, C., Jat, P., Catts, G. et al., 2017. Individual tree detection from Unmanned Aerial Vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. *Forests* **8** (9), 340. http://www.doi.org/10.3390/f8090340

Onishi, M., Ise, T., 2021. Explainable identification and mapping of trees using UAV RGB image and deep learning. *Scientific Reports* **11**, 903. http://www.doi.org/10.1038/s41598-020-79653-9

Otero, V., Van De Kerchove, R., Satyanarayana, B., Martínez-Espinosa, C., Fisol, M.A.B. et al., 2018. Managing mangrove forests from the sky: forest inventory using field data and unmanned aerial vehicle (UAV) imagery in the Matang Mangrove Forest Reserve, peninsular Malaysia. *Forest Ecology and Management* **411**, 35–45. http://www.doi.org/10.1016/j.foreco.2017.12.049

Pajares, G., 2015. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). *Photogrammetric Engineering and Remote Sensing* **81** (4), 281–330. http://www.doi.org/10.14358/PERS.81.4.281

Panagiotidis, D., Abdollahnejad, A., Surový, P., Chiteculo, V., 2017. Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing* **38** (8–10), 2392–2410. http://www.doi.org/10.1080/01431161.2016.1264028

Picos, J., Bastos, G., Míguez, D., Alonso, L., Armesto, J., 2020. Individual tree detection in a eucalyptus plantation using unmanned aerial vehicle (UAV)-LiDAR. *Remote Sensing* **12** (5), 885. http://www.doi.org/10.3390/rs12050885

Portnov, A.M., Bykhovets, S.S., Din, E.S., Ivanova, N.V., Frolov, P.V., Shanin, V.N., Shashkov, M.P., 2021. Kolichestvennaya otsenka razmerov okon v pologe starovozrastnogo shirokolistvennogo lesa nazemnymi i distantsionnymi metodami [Quantitative assessment of the size of gaps in the canopy of an old broad-leaved forest by in situ and remote methods]. *Materialy Sed'moy konferentsii «Matematicheskoe modelirovanie v ekologii» EkoMatMod-2021 [Proceedings of the Seventh Conference "Mathematical Modeling in Ecology" EcoMatMod-2021].* Pushchino, Russia, 99–102. (in Russian).

Puliti, S., Ørka, H.O., Gobakken, T., Næsset, E., 2015. Inventory of small forest areas using an unmanned aerial system. *Remote Sensing* **7** (8), 9632–9654. http://www.doi.org/10.3390/rs70809632

QGIS Development Team, 2019. QGIS Geographic Information System. Open Source Geospatial Foundation Project. URL: http://qgis.osgeo.org

R Core Team, 2021. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL: https://www.R-project.org/

Roussel, J.-R., Auty, D., Coops, N.C., Tompalski, P., Goodbody, T.R.H. et al., 2020. lidR: An R package for analysis of airborne laser scanning (ALS) data. *Remote Sensing of Environment* **251**, 112061. http://www.doi.org/10.1016/j.rse.2020.112061

Silva, C.A., Hudak, A.T., Vierling, L.A., Loudermilk, E.L., O'Brien, J.J. et al., 2016. Imputation of individual Longleaf Pine (*Pinus palustris* Mill.) tree attributes from field and LiDAR Data. *Canadian Journal of Remote Sensing* **42** (5), 554–573. https://doi.org/10.1080/07038992.2016.1196582

Silva, C.A., Klauberg, C., Mohan, M., Bright, B.C., 2018. LiDAR analysis in R and rLiDAR for forestry applications. NRS 404/504 LiDAR Remote Sensing for Environmental Monitoring. University of Idaho, Moscow, Idaho, USA, 90 p.

Sokolova, M., Japkowicz, N., Szpakowicz, S., 2008. Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. *Advances in Artificial Intelligence* **4304**, 1015–1021. http://dx.doi.org/10.1007/11941439_114

Weinstein, B.G., Marconi, S., Bohlman, S., Zare, A., White, E., 2019. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing* **11** (11), 1309. http://www.doi.org/10.3390/rs11111309

Weinstein, B.G., Marconi, S., Aubry-Kientz, M., Vincent, G., Senyondo, H., White, E.P., 2020. DeepForest: a Python package for RGB deep learning tree crown delineation. *Methods in Ecology and Evolution* **11**, 1743–1751. http://www.doi.org/10.1111/2041-210X.13472

Weinstein, B.G., Marconi, S., Bohlman, S., Zare, A., White, E., 2019. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing* **11** (11), 1309. http://www.doi.org/10.3390/rs11111309

Zhang, J., Hu, J., Lian, J., Fan, Z., Ouyang, X., YeW., 2016a. Seeing the forest from drones: testing the potential of lightweight drones as a tool for long-term forest monitoring. *Biological Conservation* **198**, 60–69. http://www.doi.org/10.1016/j.biocon.2016.03.027

Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G., 2016b. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing* **8** (6), 501. http://www.doi.org/10.3390/rs8060501