

Опыт использования нейронной сети DeepForest для детектирования деревьев в широколиственном лесу

Портнов А.М.¹, Иванова Н.В.^{1,2}, Шашков М.П.^{1,2}

¹*Институт физико-химических и биологических проблем почвоведения РАН,
ФИЦ ПНЦБИ РАН*

²*Институт математических проблем биологии РАН – филиал ИПМ им. М.В. Келдыша
РАН*

alekseyporntnow@gmail.com

DeepForest – библиотека написанная на языке Python и содержащая нейросеть для детектирования крон деревьев, предобученную на наборе изображений североамериканских лесов. Мы оценили качество работы этой нейросети на участке старовозрастного полидоминантного широколиственного леса в заповеднике «Калужские Засеки». Для этого проанализированы данные (ортофотопланы) двух разносезонных аэрофотосъемок, выполненных с помощью квадрокоптера в июне и октябре 2021 года. Участок аэрофотосъёмки размером 40 × 40 м был предварительно исследован наземными методами и проекции крон деревьев были вручную векторизованы на ортофотопланах. Затем соответствующие области ортофотопланов были обработаны с помощью функций библиотеки DeepForest. Используя результаты нейросетевого детектирования и вручную размеченные проекции крон, мы рассчитали полноту обнаружения деревьев (recall), точность (precision) и средневзвешенную оценку (F-score). Результаты детектирования по летнему ортофотоплану мы сочли удовлетворительными, деревья на осеннем ортофотоплане нейросеть детектировала существенно хуже. Сравнивая эти результаты с результатами авторов DeepForest, мы пришли к выводу, что число ложноположительных заключений нейросети остаётся относительно стабильным, в то время как число ложноотрицательных значительно варьирует в зависимости от особенностей изображения. Показано, что ключевым фактором, снижающим качество детектирования в осенний период, является отсутствие листвы на деревьях некоторых видов.

Ключевые слова: заповедник “Калужские засеки”, ортофотоплан, сегментация отдельных деревьев, дистанционные методы, precision, recall, F-score.

Experience of using the DeepForest neural network to detect trees in a broad-leaved forest

Portnov A.M.¹, Ivanova N.V.^{1,2}, Shashkov M.P.^{1,2}

¹*Institute of Physicochemical and Biological Problems in Soil Science, Pushchino Scientific Center for Biological Research of the Russian Academy of Sciences*

²*Institute of Mathematical Problems of Biology RAS - the Branch of Keldysh Institute of Applied Mathematics of Russian Academy of Sciences*

DeepForest is a Python package containing a neural network for tree crown detection, pre-trained on a set of images of North American forests. We evaluated the performance of this neural network on the site of an old-growth broad-leaved forest stand located in the Kaluzhskie Zaseki State Nature Reserve. For this purpose, we analyzed the data (orthomosaics) of two different-season aerial surveys carried out with a quadcopter in June and October 2021. The study area of 40 × 40 m was previously surveyed by ground-based methods and tree crown projections were manually detected and segmented within the orthomosaics. Then the corresponding areas of the orthomosaics were processed using DeepForest. Using the results of neural network detection and manually detected crown projections, we evaluated recall (r), precision (p), and F-score. It is shown that the quality of detection by the summer orthomosaic was satisfactory, the autumn orthomosaic was detected much worse. Comparing these results with the results of the authors of DeepForest, we concluded that the number of false positive conclusions of the neural network remains relatively stable, while the number of false negatives varies

greatly depending on the features of the image. It is shown that the key factor that reduces the quality of detection in autumn is the lack of foliage.

Key words: Kaluzhskie Zaseki Nature Reserve, orthomosaic, individual tree segmentation, remote methods, precision, recall, F-score.

Введение

Существует несколько подходов при изучении пространственной структуры древостоя. Первый предполагает использование плотных облаков точек и цифровых моделей высот древесного полога (CHM), построенных с помощью технологии LiDAR или фотограмметрии [1–3]. Другой подход заключается в анализе ортофотопланов (растровых RGB изображений) при помощи свёрточных нейронных сетей [4–6]. Одной из главных проблем второго подхода является необходимость большого массива обучающих данных [7]. Ее можно обойти, используя предобученные на других объектах нейронные сети, но остаётся открытым вопрос качества получаемых результатов. Одна из таких предобученных нейросетей – DeepForest [8, 9]. В частности, её важным достоинством является то, что она обучена на наборах данных, включающих в том числе широколиственные леса, в то время как большинство исследований, посвящённых детектированию отдельных деревьев, в качестве объекта использовали хвойные леса [10].

Целью нашего исследования является оценка качества работы этой нейросети на примере разновозрастного полидоминантного широколиственного древостоя.

Материал и методы

Исследования проводили в заповеднике “Калужские засеки” на участке постоянной пробной площади (ППП), заложенной в старовозрастном широколиственном лесу. Древостой на ППП имеет сложную структуру, состоит из нескольких ярусов. В составе древостоя 6 видов широколиственных деревьев: дуб (*Quercus robur*), ясень (*Fraxinus excelsior*), вяз (*Ulmus glabra*), клен остролистный (*Acer platanoides*), клен полевой (*A. campestre*), липа (*Tilia cordata*) и 2 мелколиственных - береза (*Betula spp.*) и осина (*Populus tremula*). Возраст наиболее старых деревьев дуба – около 300 лет [11, 12]. Размер ППП 440 × 200 м, данная работа выполнена на участке 40 × 40 м, расположенном в северо-западном углу ППП. Ранее на этом участке методом угломерной съемки нами картографировано положение всех учетных деревьев (всего 77) [13].

Для детектирования деревьев использованы ортофотопланы, полученные на основе материалов аэрофотосъемки, выполненной при помощи квадрокоптера. Съемку выполняли в 2 срока: 4 июня и 10 октября 2021 г. Фотограмметрическую обработку проводили в программе Agisoft Metashape, (версия 1.6.1.10009).

Для детектирования деревьев использовали библиотеку DeepForest, написанную на языке Python [9]. В ней содержится нейронная сеть архитектуры RetinaNet с нейросетью ResNet в качестве базового блока (backbone) [8], предобученная распознавать кроны деревьев на данных сети мониторинга NEON (National Ecological Observatory Network) (США) [14]. Нами использовались функции predict_image() и predict_tile(). Первая функция применяется ко всему изображению целиком, а вторая разбивает его на перекрывающиеся фрагменты одинакового размера и обрабатывает их по отдельности.

Для оценки качества детектирования деревьев определяли: 1) число корректно детектированных алгоритмом деревьев (TP, true positive); 2) число ложных срабатываний алгоритма, когда дерево выделено автоматически, но отсутствует на местности (FP, false positive); 3) число пропущенных деревьев, которые существуют на местности, но не детектированы алгоритмом (FN, false negative). Детектированное алгоритмом дерево классифицировали как TP в том случае, если значение показателя $IoU \geq 0.5$ (“intersection over union”, отношение пересечения площадей проекции кроны, сегментированной вручную, и построенного алгоритмом прямоугольника к их объединению). Деревья, выделенные алгоритмом за пределами ручной размеченной области, исключались из рассмотрения независимо от того, правильно ли они выделены. Результаты предварительного визуального анализа ортофотопланов не позволили с уверенностью детектировать деревья, которые потенциально могли быть найдены алгоритмом и, соответственно, рассчитать FN и FP. Поэтому были проведены полевые наземные исследования, в ходе которых для каждого учетного дерева было оценено

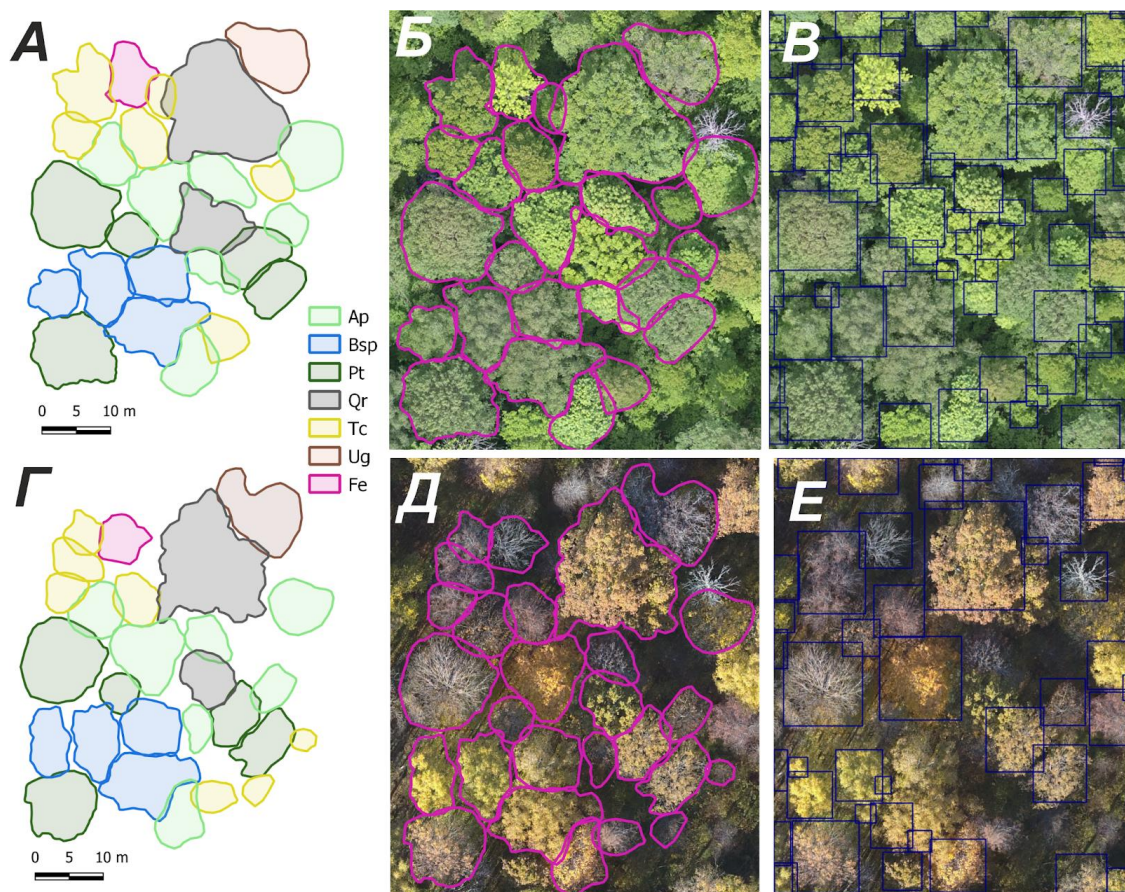


Рис. 1. Результаты ручного детектирования крон деревьев на участке постоянной пробной площади. По данным наземных исследований: А, Г – схемы проекции крон деревьев разных видов: Ap – *Acer platanoides*, Bsp – *Betula* spp., Pt – *Populus tremula*, Qr – *Quercus robur*, Tc – *Tilia cordata*, Ug – *Ulmus glabra*, Fe – *Fraxinus excelsior*. Б, Д – детектированные кроны на ортофотопланах. В, Е – по алгоритму DeepForest Сроки съемки – 4 июня 2021 г. (А, Б, В), 10 октября 2021 г. (Г, Д, Е).

положение в пологе. После этого с учетом полученных данных выполнено ручное детектирование (сегментация) крон по ортофотопланам.

Затем рассчитаны общепринятые оценки качества результатов нейросетевого детектирования по следующим формулам [15–17].

$$p = TP / (TP + FP)$$

$$r = TP / (TP + FN)$$

$$F = (2 \cdot r \cdot p) / (r + p)$$

Результаты и обсуждение

В результате наземных исследований было выяснено, что из 77 учтённых деревьев 22 относятся к верхнему ярусу древостоя, 8 деревьев высотой порядка $\frac{2}{3}$ высоты верхнего яруса находятся в межкрупных пространствах деревьев верхнего яруса, все остальные учетные деревья не видны на ортофотоплане. Таким образом, по наземным данным ожидалось, что на исследованном участке возможно автоматически детектировать 30 деревьев. В результате ручной векторизации ортофотопланов на основе наземных данных было

детектировано 26 деревьев по съемке от 4 июня и 27 деревьев – по съемке от 10 октября (рис. 1А, Б, Г, Д). Полученные результаты показывают, что для корректной оценки числа потенциально детектируемых деревьев в многовидовых лиственных лесах необходимо использовать комплексные (наземные и дистанционные) данные. Кроме того, наборы деревьев, детектированные по ортофотопланам разных сроков съемки несколько различались, что объясняется разными фенологическими фазами. На съемке от 4 июня все деревья были облиственные, в то время как на ортофотоплане от 10 октября листва уже полностью опала с липы, ясеня, вяза и, частично – с клена. Это позволило отделить друг от друга на осеннем снимке перекрывающиеся кроны лип в северо-западном углу исследованного участка. В то же время, деревья липы, растущие в межкрупных пространствах деревьев верхнего яруса, не были различимы на осеннем ортофотоплане, видимо, из-за отсутствия листвы и особенностей освещения.

Таблица 1. Оценки качества результатов анализа ортофотопланов, произведённого нейросетью

Дата съёмки	TP	FP	FN	precision	recall	F-score
04.06.2021	21	14	5	0.60	0.81	0.69
10.10.2021	13	8	14	0.62	0.48	0.54

Таблица 2. Зависимость распознавания деревьев от облиствения на снимке от 10.10.2021


	Распознанные	Нераспознанные
С листвой	9	4
Без листвы	4	10

В результате детектирования деревьев при помощи библиотеки DeepForest обнаружено, что наилучший результат даёт применение функции `predict_image()`. Использование функции `predict_tile()` давало либо тождественный (при размере обрабатываемых нейросетью фрагментов $\text{patch_size} \geq 1600$ пикселей), либо худший результат ($\text{patch_size} < 1600$ пикселей). По летнему ортофотоплану (4 июня) было вручную выделено 26 крон. Всего алгоритм выделил 64 дерева, 29 из которых находились за пределами размеченной области, таким образом, рассматривали 35 прямоугольников соответствующих кронам деревьев (табл. 1, рис. 1В). Алгоритм корректно детектировал 21 крону (TP), ещё 5 не были детектированы (FN) и 14 крон были выделены ошибочно (FP). По осеннему ортофотоплану (10 октября) было вручную выделено 27 крон (табл. 1, рис. 1Е). Всего алгоритм выделил 42 дерева, из них 21 вне рассматриваемой площади, т.е. в анализ был включен 21 прямоугольник. Выяснено, что алгоритм успешно детектировал 13 крон (TP), не смог выделить 14 (FN) и ошибочно выделил 8 (FP). Качество детектирования по летнему ортофотоплану можно признать удовлетворительным, осенний ортофотоплан нейросеть детектировала существенно хуже.

Сравнение результатов оценки качества детектирования с имеющимися для широколиственных лесов данными [9] показало что значение оценки p (точность) остаётся стабильным, как между разносезонными снимками одного объекта, так и между разными объектами (рис. 2).

Оценка же r (полнота) демонстрирует значительную вариабельность. В нашем случае, r для летнего снимка оказался выше чем у любого участка, рассмотренного в [9], а осеннего – ниже. Таким образом, мы можем предположить, что доля ошибок I рода (ложноположительных заключений) при использовании DeepForest будет оставаться относительно постоянной, в то время как доля ошибок II рода (ложноотрицательных заключений) будет возрастать при отдалении условий съёмки от условий, в которых обучалась нейронная сеть (например, при использовании снимков с деревьями без листвы). Таким образом, в зависимости от

особенностей изображений, которые анализируются при помощи данной нейросети, могут возникать как ошибки из-за пропуска существующих на местности деревьев, так и из-за детектирования ложных. С учётом этого, оценка F , представляющая собой среднее гармоническое между p и r , в случае широколиственных лесов выглядит менее информативной, чем их рассмотрение по отдельности.

**Рис. 2.** Оценки качества детектирования деревьев в широколиственных лесах при помощи DeepForest по литературным данным [9] и результатам данной работы.

Анализ результатов показал, что большую долю нераспознанных деревьев на осеннем снимке составляют липа и клён. На эти же два вида приходится ~70 % всех деревьев без листвы в размеченной области ортофотоплана (табл. 2). Мы можем заключить, что ключевым фактором низкого качества распознавания деревьев на осеннем ортофотоплане является отсутствие листвы на деревьях некоторых видов.

Полученные результаты также сравнивали с результатами для широколиственных лесов в Провинции Ляонин (Китай) [1]. Эта работа выполнена на основе анализа разносезонных плотных облаков точек LiDAR и цифровых моделей высот древесного полога. Мы можем заключить, что в нашем исследовании на летнем ортофотоплане DeepForest показал точностью большую, чем использованные в [1] алгоритмы Watershed и PCS,

которые показали $F 0.66 \pm 0.01$ для всех наборов данных (лиственный, безлиственный, смешанный). В то же время, результаты анализа композитного набора данных, составленного из разновременных съемок при помощи алгоритма LSS (сегментации стекирования слоёв) показал $F 0.74 \pm 0.01$, что значительно превосходит результат DeepForest. Однако следует учитывать, что этот результат достигнут в первую очередь за счёт повышения r (0.76 ± 0.03), в то время как r остаётся ниже (0.67 ± 0.05), чем полученный нами по данным летней съёмки. Таким образом, мы можем заключить, что нейросетевое решение в некоторых случаях превосходит решения, основанные на алгоритмах обработки плотных облаков точек, но это превосходство не является универсальным.

Таким образом, мы можем заключить, что нейросеть DeepForest может использоваться (в тех случаях, когда подходит точность IoU ≥ 0.5) без дополнительного дообучения для анализа летних ортофотопланов широколиственных лесов, но по мере опадения листвы качество результатов падает.

Благодарности

Работа выполнена при поддержке Российского научного фонда (проект №18-14-00362-П).

Список литературы

- Chen Q., Gao T., Zhu J., Wu F., Li X., Lu D., Yu F. Individual Tree Segmentation and Tree Height Estimation Using Leaf-Off and Leaf-On UAV-LiDAR Data in Dense Deciduous Forests. *Remote Sensing*. 2022. V. 14. № 12. P. 2787. doi: [10.3390/rs14122787](https://doi.org/10.3390/rs14122787)
- Otero V., Van De Kerchove R., Satyanarayana B., Martínez-Espinosa C., Fisol M.A.B., Ibrahim M.R.B., Sulong I., Mohd-Lokman H., Lucas R., Dahdouh-Guebas F. 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*. 2018. V. 411. P. 35–45. doi: [10.1016/j.foreco.2017.12.049](https://doi.org/10.1016/j.foreco.2017.12.049)
- Mohan M., Silva C.A., Klauberg C., Jat P., Catts G., Cardil A., Hudak A.T., Dia M. Individual tree detection from Unmanned Aerial Vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. *Forests*. 2017. V. 8. № 9. P. 340. doi: [10.3390/f8090340](https://doi.org/10.3390/f8090340)
- Sylvain J.-D., Drolet G., Brown N. Mapping dead forest cover using a deep convolutional neural network and digital aerial photography. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2019. V. 156. P. 14–26. doi: [10.1016/j.isprsjprs.2019.07.010](https://doi.org/10.1016/j.isprsjprs.2019.07.010)
- Li W., Fu H., Yu L., Cracknell A. Deep Learning Based Oil Palm Tree Detection and Counting for High-Resolution Remote Sensing Images. *Remote Sensing*. 2017. V. 9. № 1. P. 22. doi: [10.3390/rs9010022](https://doi.org/10.3390/rs9010022)
- Branson S., Wegner J.D., Hall D., Lang N., Schindler K., Perona P. From Google Maps to a ne-grained catalog of street trees. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2018. V. 135. P. 13–30. doi: [10.1016/j.isprsjprs.2017.11.008](https://doi.org/10.1016/j.isprsjprs.2017.11.008)
- Zhu X.X., Tuia D., Mou L., Xia G.-S., Zhang L., Xu F., Fraundorfer F. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*. 2017. V. 5. № 4. P. 8–36. doi: [10.1109/MGRS.2017.2762307](https://doi.org/10.1109/MGRS.2017.2762307)
- Weinstein B.G., Marconi S., Bohlman S., Zare A., White E. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing*. 2019. V. 11. № 11. P. 1309. doi: [10.3390/rs11111309](https://doi.org/10.3390/rs11111309)
- Weinstein B.G., Marconi S., Aubry-Kientz M., Vincent G., Senyondo H., White E.P. DeepForest: A Python package for RGB deep learning tree crown delineation. *Methods in Ecology and Evolution*. 2020. V. 11. № 12. P. 1743–1751. doi: [10.1111/2041-210X.13472](https://doi.org/10.1111/2041-210X.13472)
- Zhen Z., Quackenbush J.L., Zhang L. Trends in automatic individual tree crown detection and delineation—Evolution of LiDAR data. *Remote Sensing*. 2016. V. 8. № 4. P. 333. doi: [10.3390/rs8040333](https://doi.org/10.3390/rs8040333)
- Смирнова О.В., Чистякова А.А., Попадюк Р.В., Евстигнеев О.И., Коротков В.Н., Митрофанов М.В., Пономаренко Е.В. Популяционная организация растительного покрова лесных территорий (на примере широколиственных лесов европейской части СССР). Пушино: Научный центр биологических исследований АН СССР, 1990. 92 с.
- Shashkov M.P., Bobrovsky M.V., Shanin V.N., Khanina L.G., Grabarnik P.Ya., Stamenov M.N., Ivanova N.V. Data on 30-year stand dynamics in an old-growth broad-leaved forest in the Kaluzhskie Zaseki State Nature Reserve, Russia. *Nature Conservation Research*. 2022. V. 7. P. 24–37. doi: [10.24189/ncr.2022.013](https://doi.org/10.24189/ncr.2022.013)
- Дин Е.С., Быховец С.С., Иванова Н.В., Портнов А.М., Фролов П.В., Шанин В.Н., Шашков М.П. Сравнение различных методов наземного картографирования древостоев. *Материалы докладов XXIX Всероссийской молодежной научной конференции «Актуальные проблемы биологии и экологии» (Сыктывкар, 21–25 марта 2022 г.)*. Сыктывкар: ИБ ФИЦ Коми НЦ УрО РАН, 2022 (в печати).
- National Research Council. *Neon: Addressing the Nation's Environmental Challenges*. Washington, DC: The National Academies Press, 2004. doi: [10.17226/10807](https://doi.org/10.17226/10807)

15. Goutte C., Gaussier E. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In: *Proceedings of the European Conference on Information Retrieval, Compostela, Spain, 21–23 March 2005*. Berlin/Heidelberg: Springer, 2005. P. 345–359. doi: [10.1007/978-3-540-31865-1_25](https://doi.org/10.1007/978-3-540-31865-1_25)
16. Sokolova M., Japkowicz N., Szpakowicz S. Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. In: *AI 2006: Advances in Artificial Intelligence. Lecture Notes in Computer Science*. V. 4304. Eds. Sattar A., Kang B. Berlin/Heidelberg: Springer. 2006. P. 1015–1021. doi: [10.1007/11941439_1](https://doi.org/10.1007/11941439_1)
17. Li W., Guo Q., Jakubowski M.K., Kelly M. A new method for segmenting individual trees from the lidar point cloud. *Photogrammetric Engineering & Remote Sensing*. 2012. V. 78. № 1. P. 75–84.