

**И.С. Стешин, И.В. Петухов**

**МАШИННОЕ ОБУЧЕНИЕ БЕЗ УЧИТЕЛЯ  
НА ОСНОВЕ ВЕГЕТАЦИОННЫХ ИНДЕКСОВ  
И СПЕКТРОВ ОТРАЖЕНИЯ  
В ЗАДАЧЕ КЛАССИФИКАЦИИ ДЕРЕВЬЕВ**

*Введение.* Классификация деревьев с использованием машинного обучения стала мощным инструментом для ботаников, экологов и специалистов по охране окружающей среды, революционизируя способ идентификации и каталогизации древесных пород. Традиционные методы классификации, основанные на ручной идентификации морфологических параметров растительности, таких как листья, кора и узоры ветвления, часто являются времязатратными и трудоемкими. В противовес традиционным методам дешифрирования, алгоритмы машинного обучения могут анализировать огромные объемы данных, включая изображения, спектральную информацию и экологические переменные, для идентификации древесных пород с большей скоростью и точностью [Fassnacht et al., 2016; Wäldchen, Mäder, 2018]. Такие методы машинного обучения, как деревья решений, метод опорных векторов (SVM), полносвязные нейронные сети (FCN) и свёрточные нейронные сети (CNN), были успешно применены для автоматизации классификации пород деревьев даже в сложных экосистемах, таких как тропические леса и смешанные ландшафты. Применение подобных подходов не только способствует совершенствованию инструментов экологических исследований, но и поддерживает усилия по охране окружающей среды, где быстрая и точная идентификация видов имеет решающее значение для мониторинга биоразнообразия и борьбы с обезлесением и изменением климата [Weinstein et al., 2020; Zhong et al., 2024].

Индексы растительности, особенно те, которые получены на основе данных дистанционного зондирования, играют ключевую роль в классификации растений с использованием машинного обучения. Такие индексы, как нормализованный разностный вегетационный индекс (NDVI), усовершенствованный вегетационный индекс (EVI) и зеленый-красный вегетационный индекс (GRVI), применяются при оценке состояния здоровья и плотности растительности [Huete et al., 2002; Hamunyela et al., 2016]. Использование индексов растительности в сочетании с моделями машинного обучения по-

может улучшить точность классификации, предоставляя критически важные данные о физиологических характеристиках растений, таких как содержание хлорофилла, структура листьев и уровни влаги. Это особенно полезно для различения древесных пород, которые могут выглядеть схожими в видимом свете, но имеют уникальные спектральные сигнатуры в других диапазонах, таких как ближний инфракрасный (NIR) или красный край (680–730 нм). Алгоритмы машинного обучения могут обрабатывать большие наборы изображений, данных об индексах растительности для классификации видов растений, оценки здоровья леса и мониторинга биоразнообразия в различных экосистемах [Nevalainen et al., 2017; Onishi, Ise, 2018; Weinstein et al., 2021; Chehreh et al., 2023; Zhong et al., 2024]

Большинство исследований, связанных с применением методов машинного обучения, направлено на построение моделей, основанных на уже размеченных данных, то есть имеющих область применимости, ограниченную набором древесных пород, содержащихся в тренировочном наборе. Данная работа посвящена разработке метода классификации древесных пород, не использующего заранее подготовленный обучающий набор. Данный метод исключает продолжительный по времени этап сбора и разметки обучающих данных при построении модели, имеет высокую область применимости вне зависимости от древесной породы и при этом сохраняет высокую точность классификации.

*Материалы и методика исследования.* Для проведения исследования был выбран Нолькинский лесной участок Учебно-опытного участкового лесничества Куярского лесничества, находящийся в пользовании ФГБОУ ВО ПГТУ. Съемка была проведена 20 августа 2024 года с использованием аэрофотосъемочного комплекса Geoscan Gemini Мультиспектр (Геоскан..., 2024), высота съемки 100 м. Были выбраны 2 участка с распределением деревьев «сосна (*Pinus sylvestris* L.) / береза (*Betula pendula* Roth)» (А) и «сосна (*Pinus sylvestris*) / ель (*Picea abies* (L.) Н. Karst.)» (В), площадь каждого участка примерно 0,64 га. Данные были собраны с 5 спектральных датчиков – синего (470 нм), зеленого (560 нм), красного (665 нм), дальнего красного (720 нм) и инфракрасного (840 нм).

Данные синего, зеленого и красного спектральных каналов были объединены в RGB изображения, которые в дальнейшем использовались для детектирования крон деревьев с помощью модели DeepForest [Weinstein et al., 2019]. После завершения процесса детектирования проведен анализ и исключены случаи, когда крона дерева полностью не помещалась на изображение, а также когда выявлялась растительность, не относящаяся к деревьям (рис. 1).




Рис. 1. Идентифицированные кроны деревьев с помощью модели DeepForest, после удаления выбросов: (а) Участок А: красный – сосна, синий – береза; (б) Участок В: красный – сосна, желтый – ель

Fig. 1. Identified tree crowns using the DeepForest model, after removing outliers: (a) Plot A: red – pine, blue – birch; (b) Plot B: red – pine, yellow – fir

На основе спектральных данных были рассчитаны 30 вегетационных индексов по каждому из участков. Далее с помощью границ распознанных крон деревьев была произведена экстракция пикселей с карт вегетационных индексов и спектральных снимков.

Пиксели по каждой выбранной кроне дерева были переведены из матричного в векторный вид, и отсортированы по возрастанию. Из каждого вектора были рассчитаны следующие параметры: минимальное, максимальное, среднее, медианное значения, стандартное отклонение, а также 25-й и 75-й квантили и энтропия Шеннона [Crutchfield, Feldman, 2001; Barandas et al., 2020].

К спектральным характеристикам (вегетационный индекс / спектр отражения) каждого участка был применен алгоритм понижения размерности – метод главных компонент (PCA) [Jolliffe, Cadima, 2016] – для определения наиболее значимых параметров. Величина дисперсии, необходимой для описания набора данных, была выбрана равной 95%.

Далее на основе наиболее значимых параметров из восьми представленных выше проводилась классификация методом машинного обучения без учителя k-means ( $k = 2$ ) [Macqueen, 1967] по каждой спектральной характеристике. Этапы построения одной модели k-means по произвольной спектральной характеристике представлены на рис. 2.

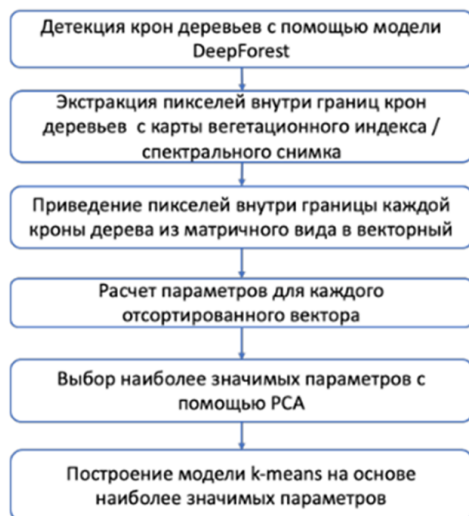


Рис. 2. Схема построения модели k-means по произвольной спектральной характеристике

Fig. 2. Scheme for constructing a k-means model based on an arbitrary spectral characteristic

В качестве метрики расстояния было использовано евклидово представление. Перед применением PCA или k-means алгоритмов данные были стандартизованы согласно уравнению (1)

$$p' = \frac{p - m}{s}, \quad (1)$$

где  $p'$  – стандартизированный параметр,  $p$  – изначальный параметр,  $m$  – среднее значение параметра,  $s$  – среднеквадратичное отклонение параметра.

Для оценки точности классификации моделей k-means были использованы следующие метрики – *Accuracy* и *F1* [Михайличенко, 2022]. Метрика *F1* была также рассчитана для каждого отдельного класса. Общий рейтинг точности классификации был отобран на основе гибридной метрики  $F1_h$  согласно уравнению (2)

$$F1_h = F1_c * F1_s, \quad (2)$$

где  $F1_c$  – среднее значение *F1* между всеми классами,  $F1_s$  – значение *F1* для класса с наименьшим количеством образцов.

На каждом участке путем глазомерной таксации были определены породы деревьев для оценки классификационной точности моделей k-means. Распределение деревьев по породам на каждом участке представлено в табл. 1.

Таблица 1

## Количество деревьев на каждом участке

## Number of trees in each plot

Участок	Древесная порода	Количество отдельных древесных пород на участке	Содержание отдельных древесных пород на участке, %
А	сосна	48	75
	береза	16	25
В	сосна	38	64
	ель	21	36

Для построения моделей машинного обучения k-means был написан код на языке Python 3 с использованием библиотек numpy [Harris et al., 2020], scipy [Virtanen et al., 2020] и scikit-learn [Pedregosa et al., 2011].

*Результаты исследования.* Проведенная классификация методом k-means демонстрирует разные результаты для исследуемых участков (рис. 3). Значения метрики  $F1$  участка В (сосна – ель) превышают соответствующие значения для участка А (сосна – береза) примерно на 25% (рис. 3). Таким образом, кластеризация, основанная на большинстве используемых в данной работе вегетационных индексов и отдельных спектров отражения, имеет сравнительно низкую классификационную способность в случае «сосна – береза».

Использование гибридных метрик  $F1_h$  и  $F1_{hb}$  (метрика  $F1_{hb}$  рассчитана аналогично  $F1_h$ , но для класса с большим количеством образцов) показывает отсутствие высокой точности классификации деревьев на участке А. В случае «сосна – береза» точность моделей k-means колеблется около  $F1 \approx 0,5$ . Дополнительный анализ метрик  $F1_h$  и  $F1_{hb}$  выявляет DVI как наиболее перспективный индекс для классификации.

Для случая «сосна – ель» точность моделей k-means  $F1 > 0,7$  для большего количества спектральных характеристик. При этом сортировка по метрике  $F1_h$  моделей для участка В имеет согласованность как для метрик  $F1$ , так и для  $Accuracy$  и  $F1_{hb}$ . Расхождения среди этих метрик начинают заметно проявляться только при достаточно низких значениях  $F1_h$ . Таким образом, классификация «сосна – ель» произведена не только с большей точностью, но и с большей выборкой различных спектральных характеристик для классификации. Значительное улучшение точности классификации моделей k-means для участка В может быть связано с тем, что участок В более сбалансирован, чем участок А, то есть в данных для участка В различные древесные породы имеют более равномерное распределение, снижая риск смещения в сторону более представленного класса (табл. 1).




Рис. 3. Оценка качества построенных моделей k-means для различных вегетационных индексов и спектров отражения. Очередность спектральных характеристик отсортирована по точности  $F1_h$  моделей для каждого участка. Участок А:  $F1_h$  (a),  $F1$  (c),  $F1_{hb}$  (e), Accuracy (g); Участок В:  $F1_h$  (b),  $F1$  (d),  $F1_{hb}$  (f), Accuracy (h)

Fig. 3. Quality assessment of constructed k-means models for various vegetation indices. The order of spectral characteristics is sorted by the accuracy of  $F1_h$  models for each plot. Plot A:  $F1_h$  (a),  $F1$  (c),  $F1_{hb}$  (e), Accuracy (g); Plot B:  $F1_h$  (b),  $F1$  (d),  $F1_{hb}$  (f), Accuracy (h)

Следует отметить, что при классификации «сосна – ель» индекс DVI, а также значения синего канала занимают лидирующие позиции, а вегетационные индексы, использующие синий спектр отражения, – нет. В то же время вегетационные индексы, использующие зеленый спектр отражения, показывают одни из худших результатов как для классификации «сосна – береза», так и для «сосна – ель».

Для оценки вклада каждого спектрального канала в классификацию с помощью вегетационных индексов были построены коробчатые диаграммы по метрике  $F1$  (рис. 4а, б). Из коробчатых диаграмм видно, что вклад дальнего красного спектрального канала является самым незначительным для обоих случаев. Максимальный вклад наблюдается для вегетационных индексов, использующих красный и инфракрасный спектральные каналы. Также данные диаграммы подтверждают, что при переходе от случая классификации «сосна – ель» к случаю «сосна – береза» наблюдается значительное снижение вкладов синего и зеленого спектров отражения. Отбор наиболее значимых параметров с помощью PCA показывает, что для построения модели классификации k-means достаточно использовать 3–4 параметра (рис. 4с, d). При этом энтропия Шеннона, максимальное и среднее значения являются наиболее частыми параметрами для описания спектральных характеристик деревьев и демонстрируют наибольшую дисперсию внутри данных по обоим участкам ((рис. 4е, f).

*Обсуждение.* Были построены модели бинарной классификации с использованием метода машинного обучения без учителя k-means и вегетационных индексов / спектров отражения для двух участков с различным распределением древесных пород (сосна – ель / сосна – береза). В задаче классификации «сосна – ель» вегетационные индексы, а также синий спектральный канал (470 нм) показывают точность, соответствующую  $F1 > 0,8$  и  $Accuracy > 0,8$ , что является близким к точности методов машинного обучения с учителем в аналогичных задачах [Nevalainen et al., 2017; Onishi, Ise, 2018]. В то же время аналогичные модели k-means для задачи классификации «сосна – береза» не достигают высокой точности, и значение метрики  $F1$  для наилучших моделей колеблется около 0,6.

Относительно невысокая точность при классификации участка «сосна – береза» может быть связана также с сезонными изменениями вегетационных индексов у сосны и березы, имеющих общую тенденцию к максимальному насыщению (достижению предельного значения) в июле – августе [Pettorelli et al., 2005; Rautiainen et al., 2009; Piekarski, Zwoliński, 2014]. Возможно, наибольшую классификационную способность данным методом можно достичь в осенний или весенний период, когда разница между хвойными и лиственными деревьями будет более значимой. При этом в обеих задачах лидирующую позицию занимает вегетационный индекс DVI по сравнению с другими аналогами.





*Заключение.* Были получены смешанные результаты по построению моделей классификации древесных пород с использованием метода машинного обучения без учителя k-means. Точность классификации модели зависит от древесных пород лесного массива. Также однозначно установлено, что DVI и синий спектр отражения (470 нм) обладают хорошими описательными характеристиками для построения моделей k-means с высокой точностью ( $FI > 0,8$ ) для лесных массивов, содержащих древесные породы «сосна – ель».

Относительно невысокая точность классификации лесного массива «сосна – береза» вскрывает проблему близких значений описательных характеристик вегетационных индексов и спектров отражения, используемых в данной работе. Дальнейшее изучение классификации древесных пород методами машинного обучения будет направлено на поиск наиболее репрезентативных вегетационных индексов, универсально описывающих большинство древесных пород, а также на разработку новых алгоритмов обработки спектральных характеристик крон деревьев.

*Вклад авторов.* И.С. Стешин – 70%, И.В. Петухов – 30%

*Сведения о финансировании исследования.* Исследование выполнено при поддержке Фонда содействия развитию малых форм предприятий в научно-технической сфере.

*Конфликт интересов.* Авторы заявляют об отсутствии конфликта интересов.

### Библиографический список

Геоскан Gemini Мультиспектр. URL: <https://www.geoscan.ru/ru/products/gemini-m> (дата обращения: 05.05.2024).

Михайличенко А.А. Аналитический обзор методов оценки качества алгоритмов классификации в задачах машинного обучения // Вестник АГУ. 2022. Вып. 4(311). С. 52–59.

Barandas M., Folgado D., Fernandes L., Santos S., Abreu M., Bota P., Liu Hui, Schultz T., Gamboa H. TSFEL: Time Series Feature Extraction Library // SoftwareX. 2020. Vol. 11. Art. no. 100456.

Chehreh B., Moutinho A., Viegas C. Latest Trends on Tree Classification and Segmentation Using UAV Data—A Review of Agroforestry Applications // Remote Sens (Basel). 2023. Vol. 15, iss. 9. Art. no. 2263.

Crutchfield J.P., Feldman D.P. Regularities Unseen, Randomness Observed: Levels of Entropy Convergence. 2001. URL: <https://arxiv.org/abs/cond-mat/0102181> (дата обращения: 14.09.2024).

Fassnacht F.E., Latifi H., Stereńczak K., Modzelewska A., Lefsky M., Waser L.T., Straub C., Ghosh A. Review of studies on tree species classification from remotely sensed data // Remote Sens Environ. 2016. Vol. 186. P. 64–87.

*Hamunyela E., Verbesselt J., Herold M.* Using spatial context to improve early detection of deforestation from Landsat time series // *Remote Sens Environ.* 2016. Vol. 172. P. 126–138.

*Harris C.R., Millman J., van der Walt S.J., Gommers R., Virtanen P., Cournapeau D., Wieser E., Taylor J., Berg S., Smith N.J., Kern R., Picus M., Hoyer S., van Kerkwijk M.H., Brett M., Haldane A., del Río J.F., Wiebe M., Peterson P., Gérard-Marchant P., Sheppard K., Reddy T., Weckesser W., Abbasi H., Gohlke H., Oliphant T.E.* Array programming with NumPy // *Nature.* 2020. Vol. 585, iss. 7825. P. 357–362.

*Huete A., Didan K., Miura T., Rodriguez E.P., Gao X., Ferreira L.G.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices // *Remote Sens Environ.* 2002. Vol. 83, iss. 1–2. P. 195–213.

*Jolliffe I.T., Cadima J.* Principal component analysis: A review and recent developments // *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences.* 2016. Vol. 374. Art. no. 2065.

*Macqueen J.* Some methods for classification and analysis of multivariate observations // *Berkeley Symp. on Math. Statist. and Prob.* 1967. P. 281–297.

*Nevalainen O., Honkavaara E., Tuominen S., Viljanen N., Hakala T., Yu Xiaowei, Hyypä J., Saari H., Pölönen I., Imai N.N., Tommaselli A.M.G.* Individual tree detection and classification with UAV-Based photogrammetric point clouds and hyperspectral imaging // *Remote Sens (Basel).* 2017. Vol. 9, iss. 3. Art. no. 185.

*Onishi M., Ise T.* Automatic classification of trees using a UAV onboard camera and deep learning. 2018. URL: <https://arxiv.org/abs/1804.10390> (дата обращения: 14.09.2024)

*Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay É.* Scikit-learn: Machine Learning in Python // *Journal of Machine Learning Research.* 2011. Vol. 12. P. 2825–2830.

*Pettorelli N., Vik J.O., Mysterud A., Gaillard J.-M., Tucker S.J., Stenseth N.C.* Using the satellite-derived NDVI to assess ecological responses to environmental change // *Trends Ecol Evol.* 2005. Vol. 20, iss. 9. P. 503–510.

*Piekarski P., Zwoliński Z.* Temporal variation in vegetation indexes for pine and beech stands during the vegetation season, Szczecin Lowland, Poland // *Quaestiones Geographicae.* 2014. Vol. 33, iss. 3. P. 131–143.

*Rautiainen M., Nilson T., Lökk T.* Seasonal reflectance trends of hemiboreal birch forests // *Remote Sens Environ.* 2009. Vol. 113, iss. 4. P. 805–815.

*Virtanen P., Gommers R., Oliphant T.E., Haberland M., Reddy T., Cournapeau D., Burovski E., Peterson P., Weckesser W., Bright J., van der Walt S.J., Brett M., Wilson J., Millman K.J., Mayorov N., Nelson A.R.J., Jones E., Kern R., Larson E., Carey C.J., Polat I., Feng Yu, Moore E.W., VanderPlas J., Laxalde D., Perktold J., Cimrman R., Henriksen I., Quintero E.A., Harris C.R., Archibald A.M., Ribeiro A.H., Pedregosa F., van Mulbregt P., SciPy 1.0 Contributors.* SciPy 1.0: fundamental algorithms for scientific computing in Python // *Nat. Methods.* 2020. Vol. 17, iss. 3. P. 261–272.

Wäldchen J., Mäder P. Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review // Archives of Computational Methods in Engineering. 2018. Vol. 25, iss. 2. P. 507–543.

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 Sens (Basel). 2019. Vol. 11, iss. 11. Art. no. 1309.

Weinstein B.G., Marconi S., Bohlman S., Zare A., White E. Cross-site learning in deep learning RGB tree crown detection // Ecol. Inform. 2020. Vol. 56. Art. no. 101061.

Weinstein B.G., Graves S.J., Marconi S., Singh A., Zare A., Stewart D., Bohlman S., White E. A benchmark dataset for canopy crown detection and delineation in co-registered airborne RGB, LiDAR and hyperspectral imagery from the National Ecological Observation Network // PLoS Comput. Biol. 2021. Vol. 17, iss. 7. Art. no. e1009180.

Zhong Lihui, Dai Zhengquan, Fang Panfei, Cao Yong, Wang Leiguang. A Review: Tree Species Classification Based on Remote Sensing Data and Classic Deep Learning-Based Methods // Forests. 2024. Vol. 15, iss. 5. Art. no. 852.

## References

Barandas M., Folgado D., Fernandes L., Santos S., Abreu M., Bota P., Liu Hui, Schultz T., Gamboa H. TSFEL: Time Series Feature Extraction Library. *SoftwareX*, 2020, vol. 11, art. no. 100456.

Chehreh B., Moutinho A., Viegas C. Latest Trends on Tree Classification and Segmentation Using UAV Data—A Review of Agroforestry Applications. *Remote Sens (Basel)*, 2023, vol. 15, iss. 9, art. no. 2263.

Crutchfield J.P., Feldman D.P. Regularities Unseen, Randomness Observed: Levels of Entropy Convergence. 2001. URL: <https://arxiv.org/abs/cond-mat/0102181> (accessed: 14.09.2024)

Fassnacht F.E., Latifi H., Stereńczak K., Modzelewska A., Lefsky M., Waser L.T., Straub C., Ghosh A. Review of studies on tree species classification from remotely sensed data. *Remote Sens Environ.*, 2016, vol. 186, pp. 64–87.

Geoscan Gemini Multispectral. URL: <https://www.geoscan.ru/ru/products/gemini-m> (accessed May 05, 2024).

Hamunyela E., Verbesselt J., Herold M. Using spatial context to improve early detection of deforestation from Landsat time series. *Remote Sens Environ.*, 2016, vol. 172, pp. 126–138.

Harris C.R., Millman J., van der Walt S.J., Gommers R., Virtanen P., Cournapeau D., Wieser E., Taylor J., Berg S., Smith N.J., Kern R., Picus M., Hoyer S., van Kerkwijk M.H., Brett M., Haldane A., del Río J.F., Wiebe M., Peterson P., Gérard-Marchant P., Sheppard K., Reddy T., Weckesser W., Abbasi H., Gohlke H., Oliphant T.E. Array programming with NumPy. *Nature*, 2020, vol. 585, iss. 7825, pp. 357–362.

Huete A., Didan K., Miura T., Rodriguez E.P., Gao X., Ferreira L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens Environ.*, 2002, vol. 83, iss. 1–2, pp. 195–213.

Jolliffe I. T., Cadima J. Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2016, vol. 374, art. no. 2065.

Macqueen J. Some methods for classification and analysis of multivariate observations. *Berkeley Symp. on Math. Statist. and Prob.*, 1967, pp. 281–297.

Mikhaylichenko A.A. Analytical review of methods for assessing the quality of classification algorithms. *ASU Bulletin*, 2022, iss. 4(311), pp. 52–59. (In Russ.)

Nevalainen O., Honkavaara E., Tuominen S., Viljanen N., Hakala T., Yu Xiaowei, Hyypä J., Saari H., Pölonen I., Imai N.N., Tommaselli A.M.G. Individual tree detection and classification with UAV-Based photogrammetric point clouds and hyperspectral imaging. *Remote Sens (Basel)*, 2017, vol. 9, iss. 3, art. no. 185.

Onishi M., Ise T. Automatic classification of trees using a UAV onboard camera and deep learning. 2018. URL: <https://arxiv.org/abs/1804.10390> (accessed: 14.09.2024)

Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay É. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 2011, vol. 12, pp. 2825–2830.

Pettorelli N., Vik J.O., Mysterud A., Gaillard J.-M., Tucker S.J., Stenseth N.C. Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends Ecol Evol.*, 2005, vol. 20, iss. 9, pp. 503–510.

Piekarski P., Zwoliński Z. Temporal variation in vegetation indexes for pine and beech stands during the vegetation season, Szczecin Lowland, Poland. *Quaestiones Geographicae*, 2014, vol. 33, iss. 3, pp. 131–143.

Rautiainen M., Nilson T., Lück T. Seasonal reflectance trends of hemiboreal birch forests. *Remote Sens Environ.*, 2009, vol. 113, iss. 4, pp. 805–815.

Virtanen P., Gommers R., Oliphant T.E., Haberland M., Reddy T., Cournapeau D., Burovski E., Peterson P., Weckesser W., Bright J., van der Walt S.J., Brett M., Wilson J., Millman K.J., Mayorov N., Nelson A.R.J., Jones E., Kern R., Larson E., Carey C.J., Polat I., Feng Yu, Moore E.W., VanderPlas J., Laxalde D., Perktold J., Cimrman R., Henriksen I., Quintero E.A., Harris C.R., Archibald A.M., Ribeiro A.H., Pedregosa F., van Mulbregt P., SciPy 1.0 Contributors. SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nat. Methods*, 2020, vol. 17, iss. 3, pp. 261–272.

Wäldchen J., Mäder P. Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review. *Archives of Computational Methods in Engineering*, 2018, vol. 25, iss. 2, pp. 507–543.

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 Sens (Basel)*, 2019, vol. 11, iss. 11, art. no. 1309.

Weinstein B.G., Marconi S., Bohlman S., Zare A., White E. Cross-site learning in deep learning RGB tree crown detection. *Ecol. Inform.*, 2020, vol. 56, art. no. 101061.

Weinstein B.G., Graves S.J., Marconi S., Singh A., Zare A., Stewart D., Bohlman S., White E. A benchmark dataset for canopy crown detection and delineation in co-

registered airborne RGB, LiDAR and hyperspectral imagery from the National Ecological Observation Network. *PLoS Comput. Biol.*, 2021, vol. 17, iss. 7, art. no. e1009180.

Zhong Lihui, Dai Zhengquan, Fang Panfei, Cao Yong, Wang Leiguang. A Review: Tree Species Classification Based on Remote Sensing Data and Classic Deep Learning-Based Methods. *Forests*, 2024, vol. 15, iss. 5, art. no. 852.

Материал поступил в редакцию 14.10.2024

---

**Стешин И.С., Петухов И.В.** Машинное обучение без учителя на основе вегетационных индексов и спектров отражения в задаче классификации деревьев // Известия Санкт-Петербургской лесотехнической академии. 2025. Вып. 255. С. 89–102. DOI: 10.21266/2079-4304.2025.255.89-102

Статья посвящена применению метода машинного обучения k-means и вегетационных индексов для классификации древесных пород на основе материалов съемки с БПЛА. Вегетационные индексы анализируют спектральные характеристики растений, что особенно полезно для классификации схожих видов деревьев, поскольку они имеют разные спектральные сигнатуры. Исследование проведено на двух лесных участках с распределением деревьев «сосна – береза» и «сосна – ель». Данные были собраны с 5 спектральных датчиков – синего (470 нм), зеленого (560 нм), красного (665 нм), дальнего красного (720 нм) и инфракрасного (840 нм). Детекция крон деревьев была произведена по RGB изображениям, полученным с помощью спектральных датчиков и модели DeepForest. Далее внутри границы детектированных крон деревьев данные со спектральных датчиков обрабатывались для расчета вегетационных индексов каждого дерева. Пиксели по каждому дереву из матричного вида были разложены в вектор, отсортированный по возрастанию. Из каждого вектора были рассчитаны следующие параметры: минимальное, максимальное, среднее, медианное значения, а также 25-й и 75-й квантили и энтропия Шеннона. После чего применялся метод понижения размерности PCA и кластеризации k-means для разделения типов деревьев. Результаты показали, что в случае с сосной и елью точность классификации превышала 80%, тогда как для сосны и березы метрики были менее успешными, что может быть связано с сезонными изменениями индексов. В обоих случаях лучшими индикаторами оказались DVI, демонстрируя высокую эффективность для определенных лесных покрытий.

**Ключевые слова:** машинное обучение, таксация деревьев, вегетационные индексы, БПЛА.

**Steshin I.S., Petukhov I.V.** Unsupervised machine learning based on vegetation indices and reflectance spectra for tree classification. *Izvestia Sankt-Peterburgskoj Lesotehnickeskoj Akademii*, 2025, iss. 255, pp. 89–102 (in Russian with English summary). DOI: 10.21266/2079-4304.2025.255.89-102

The article is devoted to the use of the k-means machine learning method and vegetation indices for the classification of tree species based on UAV survey materials. Vegetation indices analyze the spectral characteristics of plants, which is especially useful for distinguishing similar tree species, as they exhibit different spectral signatures. The study was conducted on two forest plots with tree distributions of pine-birch and pine-spruce. Data were collected from five spectral sensors: Blue (470 nm), Green (560 nm), Red (665 nm), Far Red (720 nm), and Infrared (840 nm). Tree crown detection was performed using RGB images captured by spectral sensors and the DeepForest model. Within the boundaries of the detected crowns, spectral sensor data were processed to calculate the vegetation indices for each tree. Pixels for each tree from the matrix view were decomposed into a vector, sorted in ascending order. The following parameters were calculated from each vector: minimum, maximum, mean, median values, as well as the 25th and 75th percentiles and Shannon entropy. Dimensionality reduction via PCA and k-means clustering were then applied to differentiate tree types. The results showed that for pine and spruce, classification accuracy exceeded 80%, whereas for pine and birch, the metrics were less successful, possibly due to seasonal changes in the indices. In both cases, DVI proved to be the most effective indicator, demonstrating high efficiency for certain forest covers.

**Key words:** machine learning, tree identification, vegetation indices, UAV

---

**СТЕШИН Илья Сергеевич** – младший научный сотрудник Поволжского государственного технологического университета. ORCID: 0009-0009-4241-3798. 424000, пл. Ленина, д. 3, г. Йошкар-Ола, Республика Марий Эл, Россия. E-mail: [ilyasteshinm@yandex.ru](mailto:ilyasteshinm@yandex.ru)

**STESHIN Ilya S.** – junior researcher at Volga State Technological University. ORCID: 0009-0009-4241-3798. 424000. Lenin sq. 3. Yoshkar-Ola. Mari El. Russia. E-mail: [ilyasteshinm@yandex.ru](mailto:ilyasteshinm@yandex.ru)

**ПЕТУХОВ Игорь Валерьевич** – профессор кафедры проектирования и производства электронно-вычислительных средств Поволжского государственного технологического университета, доктор технических наук. SPIN-код: 6009-1846. ORCID: 0009-0000-2365-4857.

424000, пл. Ленина, д. 3, г. Йошкар-Ола, Республика Марий Эл, Россия. E-mail: [PetuhovIV@volgatech.net](mailto:PetuhovIV@volgatech.net)

**PETUKHOV Igor V.** – DSc (Technical), Professor of the Department of Design and Production of Electronic Computing Tools, Volga State Technological University. SPIN-code: 6009-1846. ORCID: 0009-0000-2365-4857.

424000. Lenin Sq. 3. Yoshkar-Ola. Mari El. Russia. E-mail: [PetuhovIV@volgatech.net](mailto:PetuhovIV@volgatech.net)