

Научная статья
УДК 519.651
DOI: 10.14529/build250209

РАСПОЗНАВАНИЕ И КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ ПРИРОДНЫХ РЕСУРСОВ НА СПУТНИКОВЫХ СНИМКАХ С ПОМОЩЬЮ НЕЙРОСЕТЕВОГО АЛГОРИТМА

Е.В. Попов, П.В. Юрченко[✉]

*Нижегородский государственный архитектурно-строительный университет,
Нижний Новгород, Россия*
[✉] pavel-yurchenko@list.ru

Аннотация. В статье описан алгоритм распознавания и классификации изображений природных ресурсов на спутниковых снимках, использующий методы машинного обучения с учителем, при подготовке обучающего набора данных которого использовались четыре различных подхода: Gaussian Mixture Model, Random Forest, Support Vector Machines, K-Nearest Neighbors. Экспериментально установлены параметры архитектуры нейросети, позволяющие классифицировать природные ресурсы с наибольшей точностью.

Ключевые слова: распознавание и классификация изображений, спутниковые снимки, нейросеть, природные ресурсы

Для цитирования. Попов Е.В., Юрченко П.В. Распознавание и классификации изображений природных ресурсов на спутниковых снимках с помощью нейросетевого алгоритма // Вестник ЮУрГУ. Серия «Строительство и архитектура». 2025. Т. 25, № 2. С. 72–82. DOI: 10.14529/build250209

Original article
DOI: 10.14529/build250209

RECOGNITION AND CLASSIFICATION OF NATURAL RESOURCE IMAGES IN SATELLITE IMAGES USING THE NEURAL NETWORK ALGORITHM

E. V. Popov, P. V. Yurchenko[✉]

*Nizhny Novgorod State University of Architecture and Civil Engineering,
Nizhny Novgorod, Russia*
[✉] pavel-yurchenko@list.ru

Abstract. The paper describes an algorithm for recognizing and classifying natural resource images in satellite images using machine learning methods with a tutor. Four different approaches were used to train the training dataset: Gaussian Mixture Model, Random Forest, Support Vector Machines, and K-Nearest Neighbors. The parameters of the neural network architecture were experimentally established, which allows classifying natural resources with maximum accuracy.

Keywords: image recognition and classification, satellite images, neural network, natural resources

For citation. Popov E.V., Yurchenko P.V. Recognition and classification of natural resource images in satellite images using the neural network algorithm. *Bulletin of the South Ural State University. Ser. Construction Engineering and Architecture*. 2025;25(2):72–82. (in Russ.). DOI: 10.14529/build250209

Введение

Природные и антропогенные объекты, расположенные на поверхности Земли, представляют собой основную среду для существования и развития человеческого общества. Изменения, происходящие с природными и антропогенными объектами с течением времени, могут иногда оказывать негативное влияние и даже быть опасными для человеческого сообщества и животных. Некоторые подобные изменения могут быть естественными, некоторые могут носить отпечаток результатов человеческой деятельности, но в целом все они как правило взаимосвязаны и зависят от объективных причин. К объективным причинам можно отнести такие факторы, как экономический рост в пределах городских территорий и территорий иных населённых пунктов, что приводит к притоку населения и вызывает естественное изменение границ антропогенных объектов, которое, в свою очередь, влечёт за собой изменения границ объектов природных. К негативным изменениям можно отнести уменьшение территорий, занятых лесными массивами, водными объектами, что влечёт неизбежное ухудшение экологической ситуации. В случае, если природные ресурсы являются критически важными для экономики рассматриваемой территории, то любое изменение их границ, сокращение площадей, ухудшение качественных характеристик провоцирует рост и других негативных последствий. Прогнозирование подобных изменений для своевременного реагирования и поиска путей сглаживания их последствий является важной и актуальной задачей [1]. Для сокращения трудоёмкости процесса отслеживания изменений в геометрии и атрибутивных характеристиках природных и антропогенных объектов необходимо использовать методы и алгоритмы распознавания изображений изучаемых объектов на спутниковых снимках. Одной из актуальных задач при разработке алгоритмов распознавания изображений является задача классификации изображений на спутниковых снимках, решению которой посвящена настоящая статья.

1. Существующие подходы к решению задачи

Задачи, связанные с различными аспектами классификации изображений природных и антропогенных объектов на спутниковых снимках, довольно часто встречаются в современных исследованиях и публикациях. Распознавание изображений тех или иных объектов, получаемое с помощью материалов дистанционного зондирования, позволяет лучше и точнее представить их расположение, характеристики занимаемой площади и, следовательно, более эффективно управлять ими в перспективе. При выборе подходов к классификации природных ресурсов исследователи опираются на конкретные цели и доступные им технологические и технические возможности. Так, классификации изображений сельскохозяйственных зе-

мель, в том числе земель, предназначенных для скотоводства, уделено внимание в [2–4]. В случаях [2, 3] предполагается применение нейросетевых алгоритмов, встроенных в готовые модули геоинформационной системы QGIS (далее – ГИС QGIS), что естественным образом может ограничить вариативность проводимого эксперимента. Многие зарубежные исследования по классификации изображений природных и антропогенных объектов основаны на использовании сверточных нейронных сетей [4–8], что предполагает большие затраты на техническую составляющую эксперимента. К тому же применение технологий глубокого обучения предполагает и существенное увеличение исходных данных, предварительно обработанных согласно целям эксперимента [9–11]. Исследователи взаимных изменений геометрии природных и антропогенных объектов в Берхампоре (Индия) описывают не только саму классификацию указанных объектов на спутниковых снимках, но и прогнозирование дальнейшего развития этих изменений до 2031 года [12]. Предложенный метод прогнозирования опирается на применение сторонних программных решений, основанных на нейросетевом алгоритме с использованием клеточного автомата Маркова.

Упомянутые алгоритмы являются довольно точными и требуют большой подготовительной работы и значительных технических ресурсов или опоры на сторонние облачные среды, что не всегда возможно или оправданно [8, 13–17]. Вместе с тем для решения задачи прогнозирования изменений геометрии природных объектов, например, лесных массивов, которая является ближайшей перспективой текущего исследования, точность, достигаемая при использовании менее затратных во всех отношениях алгоритмов обучения с учителем, является вполне достаточной [18]. Она позволяет зафиксировать главное – тенденцию и скорость изменений.

2. Алгоритм распознавания и классификации изображений объектов

Каждая территория на поверхности Земли характеризуется большим объемом данных. При изучении геометрических характеристик значительных по площади объектов, таких как лесные массивы, эти данные лучше всего получать со спутниковых снимков. Доступность спутниковых данных, полученных различными датчиками, способствует успешному проведению исследования [19]. В основу описываемого алгоритма была положена идея комплексного использования возможностей ГИС QGIS и методов машинного обучения, реализованных на языке Python, в частности нейросетевых алгоритмов. Методы обработки и анализа изображений, полученных в результате дистанционного зондирования Земли, использованные в данной работе, включают предварительный отбор сцен снимков без облаков и шумов,

подготовку и разметку векторных слоев, настройку параметров классификаторов для создания набора данных [20]. Этот подход опирался на геопространственные данные, полученные со спутниковых снимков LANDSET-8, и известные алгоритмы классификации. Подготовка обучающих наборов данных для автоматизированного распознавания лесных массивов на спутниковых снимках с использованием указанных алгоритмов машинного обучения происходила в среде QGIS. Наборы данных были созданы с опорой на четыре различные модели машинного обучения: Gaussian Mixture Model (GMM), Random Forest (RF), Support Vector Machines (SVM), K-Nearest Neighbors (KN). При этом искусственная нейронная сеть была использована для автоматизированной классификации лесных массивов на тестовом многоканальном растре.

Блок-схема алгоритма представлена на рис. 1, этапы описываемого алгоритма следующие:

- 1) получение данных спутниковых снимков;
- 2) подготовка обучающих наборов данных (QGIS, 4 метода подготовки);
- 3) нейронная сеть (обучение с учителем) – оценка точности и потерь при использовании различных методов формирования набора данных;
- 4) результат автоматизированной классификации природных объектов для дальнейшего анализа и следующих этапов исследования.

Тестирование алгоритма проводилось на материалах спутниковых снимков, взятых за разные периоды времени и отображающих территории Большеболдинского муниципального округа Нижегородской области. При разработке нейросетевого алго-



Рис. 1. Этапы алгоритма

ритма учитывался ряд особенностей распознаваемых объектов.

Во-первых, у классифицируемых объектов на снимках нет типичных контуров, которые можно использовать для обучения нейросети.

Во-вторых, файл формата geotiff, в котором хранятся спутниковые снимки, состоит из нескольких слоев, число которых зависит от количества спектров, в которых делается снимок. Эта особенность зависит от типа спутника, и распознавание объектов на таких снимках требует выделения из снимков тех спектров, в которых распознаваемые объекты видны наилучшим образом.

В-третьих, при отборе снимков необходимо учитывать временные аспекты, так как в определенное время года над изучаемой местностью могут быть скопления облаков, затрудняющие их дешифрирование и последующую классификацию изображенных на них объектов.

В данной работе были выбраны спутниковые снимки, сделанные летом 2016 года спутником LANDSAT-8 (запущен 11.02.2013), имеющим сенсоры OLI (Operational Land Imager) и TIRS (Thermal Infrared Sensor); у спутника 11 каналов, из них 8 с разрешением 30 м/пикс в видимом, ближнем инфракрасном (каналы 1–5 и 9) и среднем инфракрасном (номера каналов 6, 7), 2 канала (10, 11) с разрешением 100 м/пикс в тепловом диапазоне, а также панхроматический канал (8) с разрешением 15 м/пикс. Следует отметить, что канал 1 находится в ультрафиолетовой части спектра [20]. Для исследований объектов на поверхности Земли наиболее востребованы каналы с номера-

ми 1–7 с разрешением 30 м/пикс, общее число комбинаций которых составляет 343. Для создания набора данных растровый снимок был собран в QGIS из первых семи каналов, при этом в дальнейших действиях для автоматической классификации с использованием технологий машинного обучения были взяты каналы со 2-го по 7-й.

Далее из полученного снимка были взяты фрагменты одинаковой размерности, содержащие классифицируемые объекты – лесные массивы. При дальнейшей обработке первого фрагмента снимка был выделен его полигональный слой, на котором отмечены эталонные полигоны, соответствующие лесным массивам, и эталонные полигоны, им не соответствующие. Количество полигонов каждого типа было взято одинаковым (рис. 2). Обрабатываемый снимок и векторный слой были привязаны к единой системе координат – EPSG: 32638.

В качестве основного плагина для классификации объектов на спутниковых снимках был выбран плагин dzetsaka [21]. После его установки в среде QGIS были заданы необходимые параметры: входной растр, векторный слой с выделенными эталонными полигонами (см. рис. 2), тип алгоритма машинного обучения для разметки растра и сам результат разметки – одноканальный растр. Таким образом, после использования каждого алгоритма был получен соответствующий одноканальный растр (рис. 3). Входной многоканальный и выходной одноканальный растры в паре представляли собой набор данных для дальнейшего применения в нейросети с учителем. Всего были созданы че-



Рис. 2. Векторный слой с выделенными полигонами

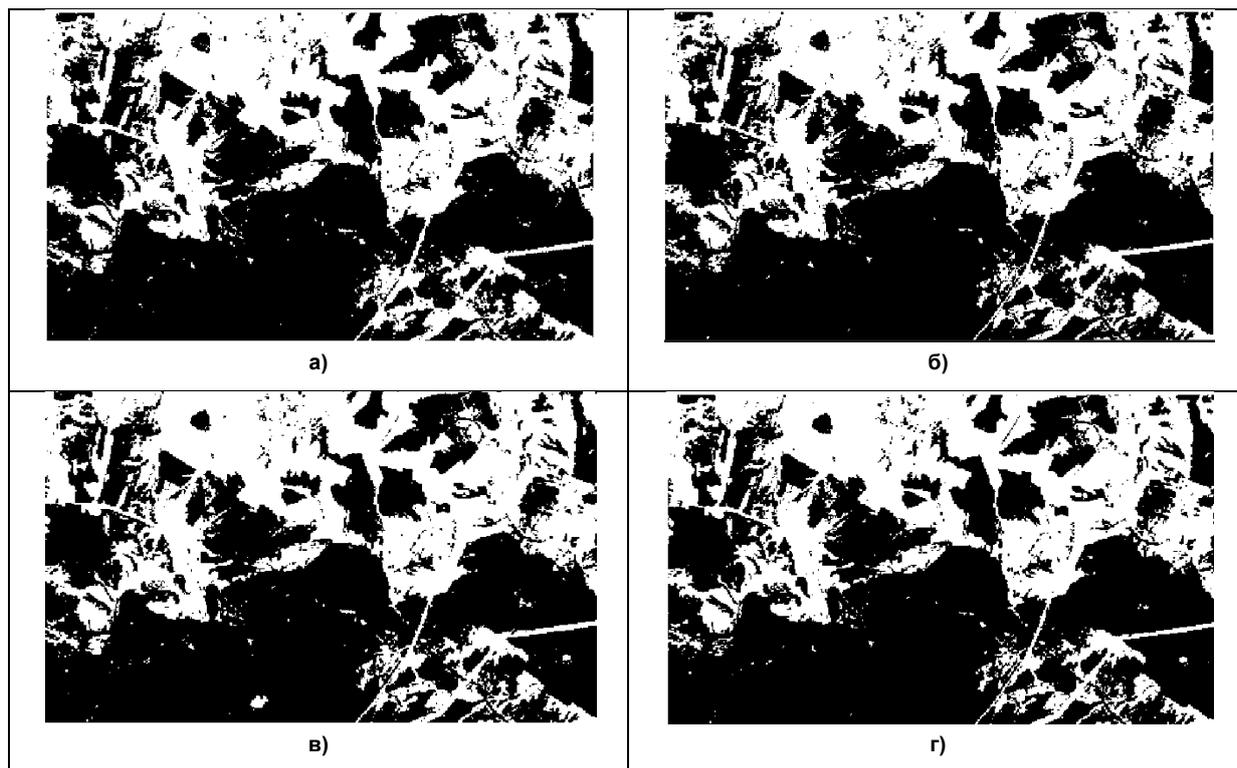


Рис. 3. Одноканальные растры, полученные методами классификации:
а – Gaussian Mixture Model; б – Random Forest; в – Support Vector Machines; г – K-Nearest Neighbors

тыре набора данных для дальнейшего использования в создаваемой нейросети.

Подготовка и настройка структуры и параметров нейросети производились на языке программирования Python в среде Google Colab, используемые библиотеки: tensorflow, sklearn, pyrsgis [22, 23]. Pyrsgis – библиотека для обработки снимков, среди ее функций – перевод растра в цифровую матрицу (массив), изменение размерности массива (перевод матрицы в вектор), обратная трансформация вектора в массив и далее в растр для вывода результата автоматической классификации описана в [22].

Была построена нейронная сеть прямого пространства, основа которой – многослойный персептрон, реализующий алгоритм обратного распространения ошибки. При построении архитектуры сети были использованы два скрытых слоя, первый из которых имел 14 входных узлов, в качестве функции активации использовалась сигмоида. Второй слой имел два входных узла, и в качестве функции активации использовалась функция ReLu, так как в алгоритме применялась дихотомическая классификация и разметка растра производилась по принципу «лес – не лес». Количество эпох обучения подбиралось эмпирическим путем.

Был произведен подбор соотношения количества узлов, количества эпох обучения сети и анализ полученных значений стандартных метрик. В начале каждый набор данных был использован

в нейросетевых алгоритмах с двумя эпохами, а затем с шестью эпохами.

Для обучения нейронной сети в каждом этапе эксперимента подготовленные наборы данных разделялись на обучающие и валидационные в соотношении 60/40. Анализ получаемых классифицированных одноканальных растров показал необходимость нормирования получаемых в результате классификации данных. Благодаря этому было достигнуто более четкое разделение классифицируемых объектов и остальной территории на снимке, то есть исключить пиксели серых тонов на одноканальном растре – результате классификации (для них значение вероятности принадлежности к лесным массивам составляло менее 0,9). Успешность модели подтверждают не только значения метрик, но и показатели матриц ошибок, формируемые автоматически после стадии обучения нейросетевого алгоритма, в которых указаны данные о количестве пикселей, относящихся к лесным массивам, но классифицированных иначе и наоборот, а также количество верно классифицированных пикселей.

3. Результаты тестирования алгоритма

В результате тестирования алгоритма были получены данные, позволяющие говорить об успешном построении модели, которая имеет сравнительно простую структуру, но в то же время эффективный результат применения. Анализ матрицы ошибок показывает увеличение числа верно

распознаваемых пикселей с увеличением количества итераций практически во всех случаях, кроме случая, когда набор данных для обучения создавался с применением метода опорных векторов (табл. 1). Автоматически рассчитанные на основе показателей матрицы ошибок точность и полнота во всех способах классификации, принятых при подготовке набора данных, превысили порог в 0,9 (табл. 2). Диаграммы иллюстрируют результаты работы алгоритма с исходными наборами данных, созданными с помощью четырех способов классификации данных при двух итерациях в алгоритме (рис. 4, а) и при шести (рис. 4, б).

В результате в каждом из этапов эксперимента путем применения нейросетевого алгоритма был получен одноканальный растр, на котором были выделены исследуемые природные объекты – лесные массивы. При сравнении с эталонным участком карты расхождения с классифицированным растром были незначительные на каждом этапе эксперимента. Диаграммы иллюстрируют данные классификации, полученные в результате применения алгоритма с двумя итерациями (рис. 5) и с шестью итерациями (рис. 6).

Выводы

Проведенные эксперименты показали, что все выбранные для создания набора данных алгорит-

мы в целом дают хороший результат после применения на тестовом растре. При этом наименее результативным все же оказался алгоритм, использующий набор данных, созданный при помощи Support Vector Machines, наиболее результативным – использующий алгоритм, созданный при помощи обучающего набора данных, подготовленного методом Random Forest. Вместе с тем увеличение числа итераций (эпох) с двух до шести привело к улучшению результатов работы алгоритма, использующего для обучения набор данных, подготовленный методом Support Vector Machines, в то время как использование методов K-Nearest Neighbors и Gaussian Mixture Model для подготовки исходных данных алгоритма классификации показало незначительное ухудшение показателя точности распознавания классифицируемых пикселей.

Дальнейшие этапы проводимого исследования предполагают применение нейросетевых алгоритмов для прогнозирования возможных изменений в геометрии природных ресурсов с течением времени и определение факторов, влияющих на эти изменения. Исследование рассмотренных алгоритмов классификации изображений на спутниковых снимках продолжится в разрезе выбора наиболее успешных подходов для целей прогнозирования.

Таблица 1

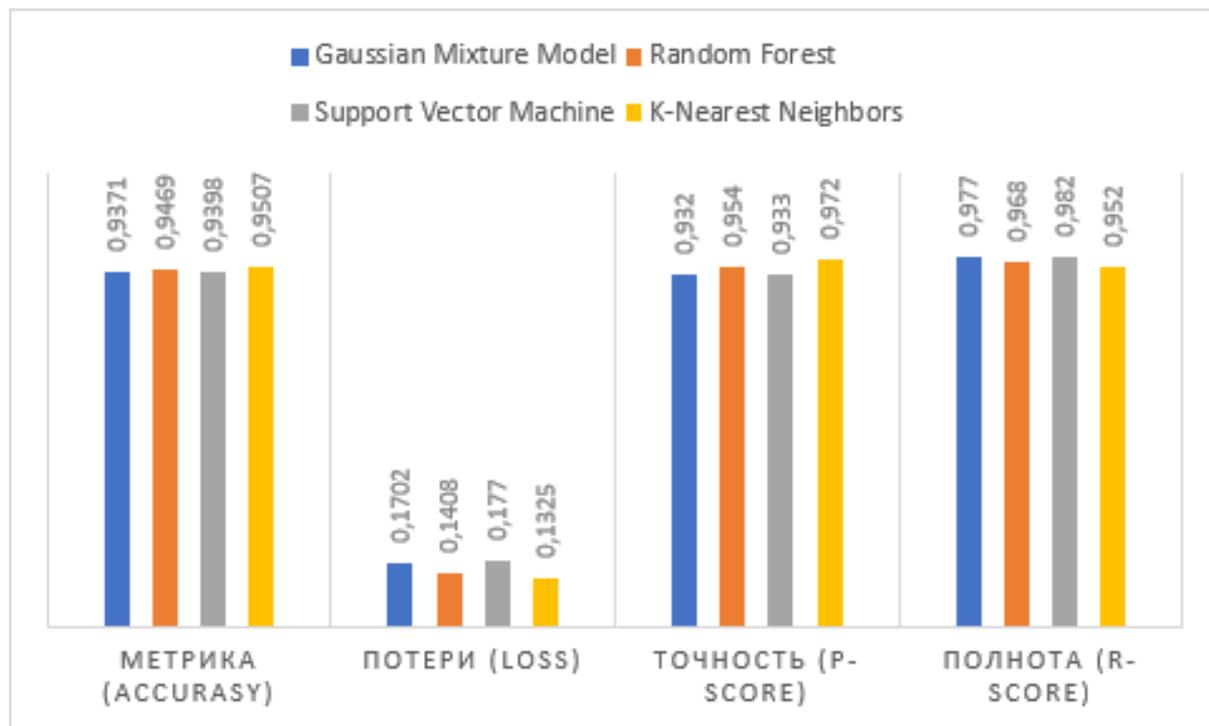
Confusion Matrixes по данным эксперимента

Модель подготовки обучающего набора данных для алгоритма	Количество итераций (эпох обучения)	True Negative	False Positive	False Negative	True Positive
Gaussian Mixture Model	2	17252	2026	663	27663
Random Forest	2	17316	1341	942	28105
Support Vector Machines	2	17248	2010	510	27936
K-Nearest Neighbors	2	17750	807	1399	27748
Gaussian Mixture Model	6	17606	1672	378	28048
Random Forest	6	17945	712	1140	27907
Support Vector Machines	6	18519	739	1161	27285
K-Nearest Neighbors	6	17142	1415	597	28550

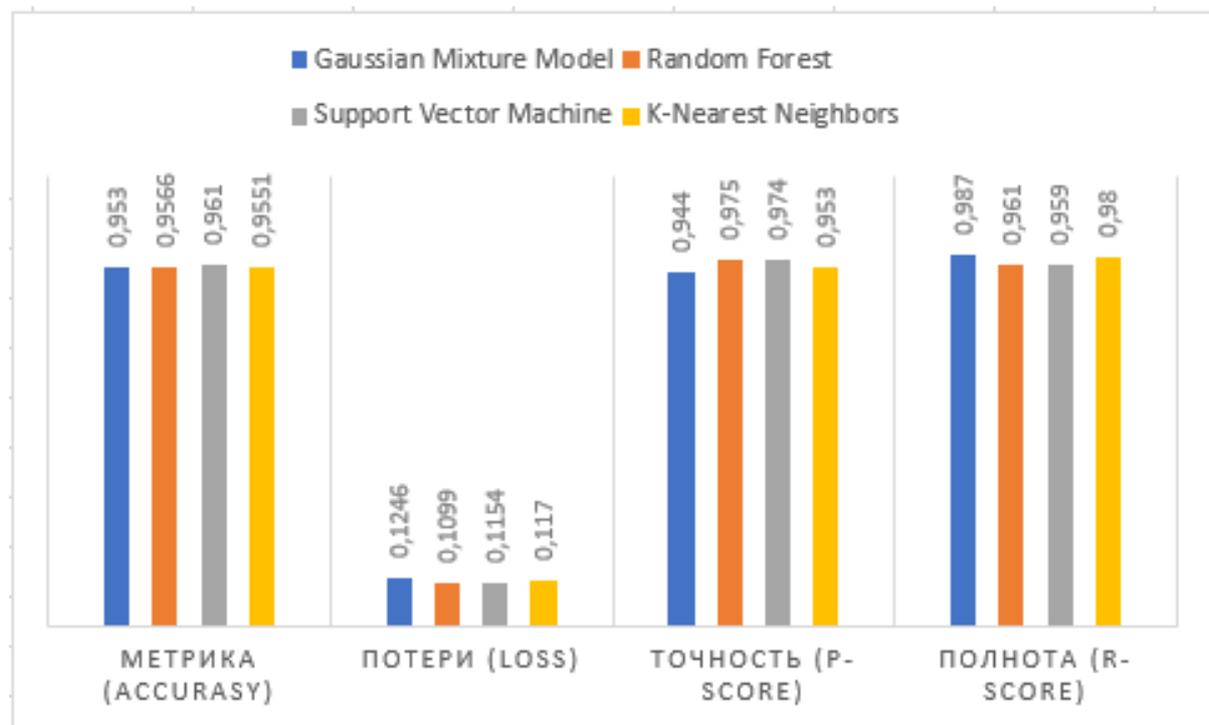
Таблица 2

Количественные данные эксперимента

Модель подготовки обучающего набора данных для алгоритма	Количество итераций (эпох обучения)	Метрика (accuracy)	Потери (loss)	Точность (P-Score)	Полнота (R-Score)
Gaussian Mixture Model	2	0,9371	0,1702	0,932	0,977
Random Forest	2	0,9469	0,1408	0,954	0,968
Support Vector Machines	2	0,9398	0,1770	0,933	0,982
K-Nearest Neighbors	2	0,9507	0,1325	0,972	0,952
Gaussian Mixture Model	6	0,9530	0,1246	0,944	0,987
Random Forest	6	0,9566	0,1099	0,975	0,961
Support Vector Machines	6	0,9610	0,1154	0,974	0,959
K-Nearest Neighbors	6	0,9551	0,1170	0,953	0,980



а)



б)

Рис. 4. Результат работы алгоритма классификации: а – с двумя итерациями; б – с шестью итерациями

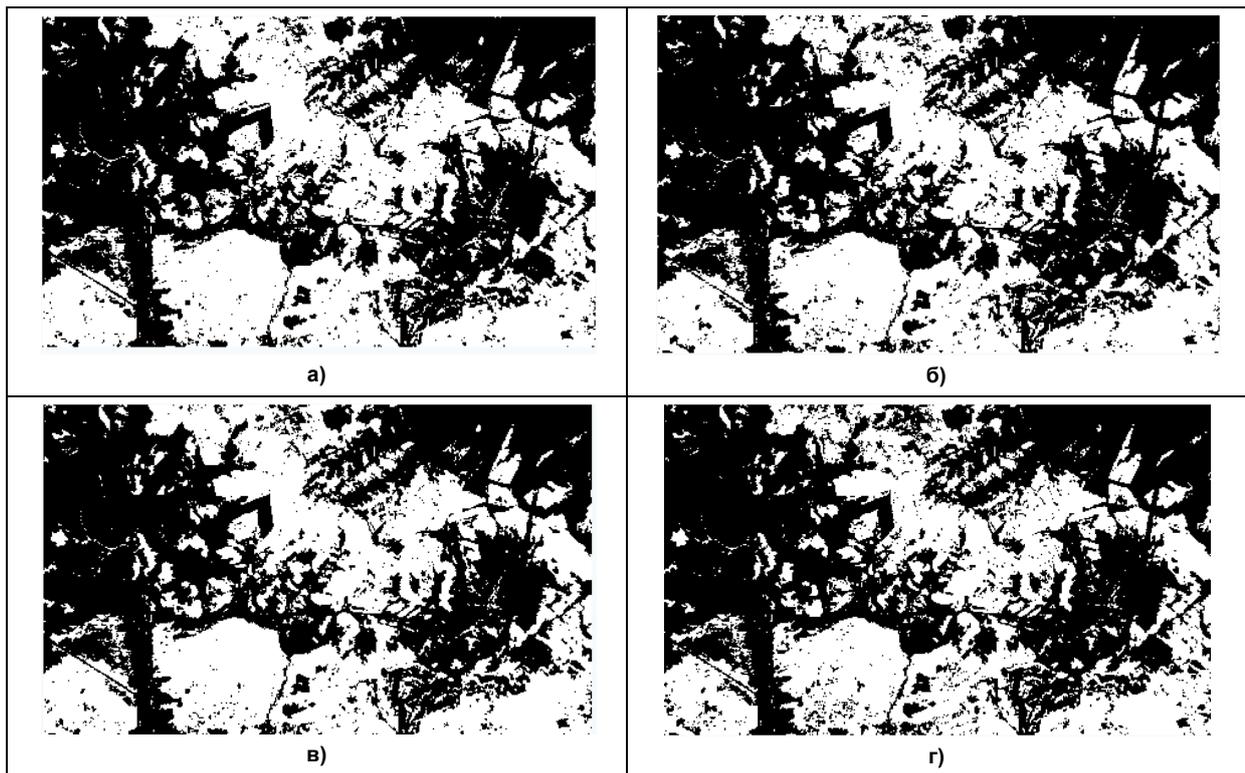


Рис. 5. Результаты классификации алгоритма с двумя итерациями с обучающими наборами данных, подготовленными методами: а – Gaussian Mixture Model; б – Random Forest; в – Support Vector Machines; г – K-Nearest Neighbors

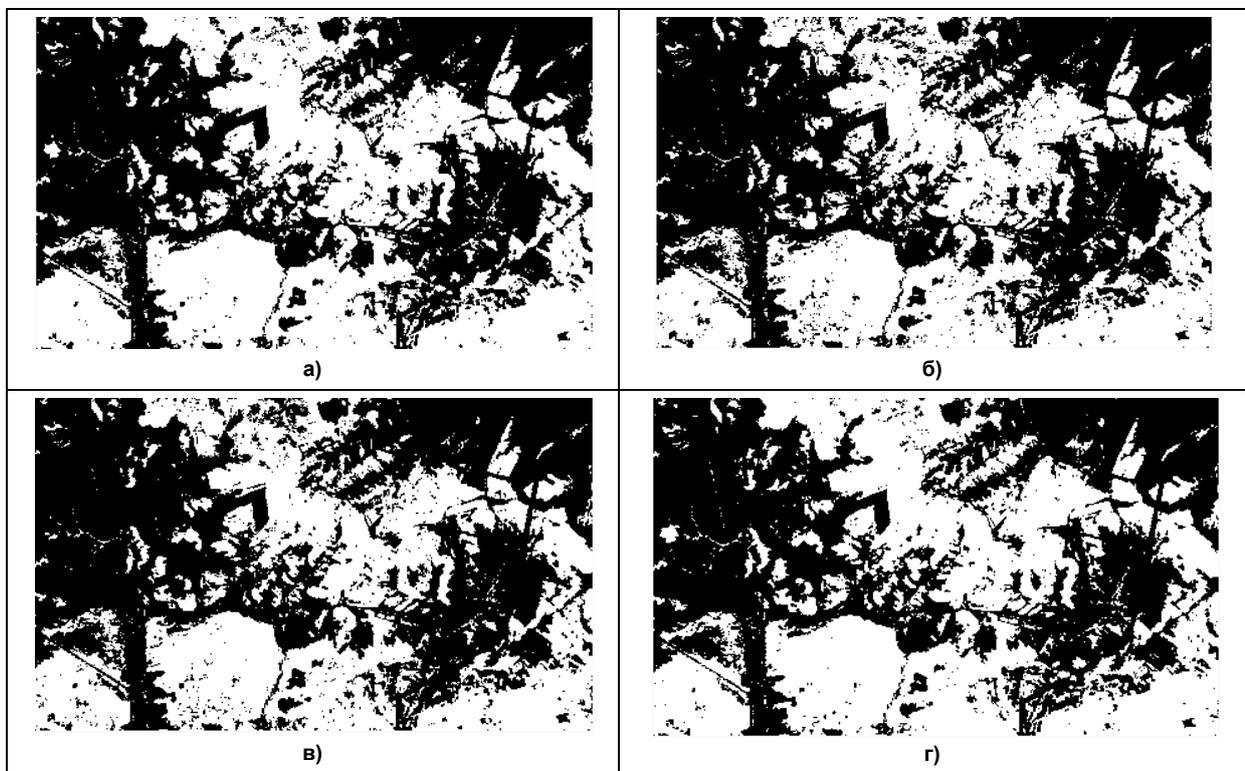


Рис. 6. Результаты классификации алгоритма с шестью итерациями с обучающими наборами данных, подготовленными методами: а – Gaussian Mixture Model; б – Random Forest; в – Support Vector Machines; г – K-Nearest Neighbors

Список литературы

1. Состояние и перспективы развития методов спутникового картографирования растительного покрова России / С.А. Барталев, В.А. Егоров, В.О. Жарко и др. // Современные проблемы дистанционного зондирования Земли из космоса. 2015. Т. 12, № 5. С. 203–221.
2. Елсаков В.В., Щанов В.М. Современные изменения растительного покрова пастбищ северного оленя Тиманской тундры по результатам анализа данных спутниковой съёмки // Современные проблемы дистанционного зондирования Земли из космоса. 2019. Т. 16, № 2. С. 128–142. DOI: 10.21046/2070-7401-2019-16-2-128-142
3. Леванков А.Н., Дудкин А.А. Нейросетевая идентификация неиспользуемых сельскохозяйственных земель на снимках дистанционного зондирования земли в системе QGIS // BIG DATA and Advanced Analytics = BIG DATA и анализ высокого уровня: сборник научных статей VII Международной научно-практической конференции, Минск, 19–20 мая 2021 года / редкол.: В.А. Богуш [и др.]. Минск: Бестпринт, 2021. С. 102–109. URL: <https://libeldoc.bsuir.by/handle/123456789/43890> (дата обращения 20.03.2024).
4. Fazzini P., De Felice Proia G., Adamo M., Blonda P., Petracchini F., Forte L., Tarantino C. Sentinel-2 remote sensed image classification with patchwise trained ConvNets for grassland habitat discrimination // Remote Sensing. 2021. Vol. 13(12), pp. 2276. DOI: 10.3390/rs13122276
5. Kaganga L.S., Ngogo N.M. Impact of land use and land cover changes on ecosystem services value in Mwanza city, Tanzania // Asian Journal of Environment & Ecology. 2024. Vol. 23(5), pp. 30–40. DOI: 10.9734/ajee/2024/v23i5545
6. Assessment of deep learning techniques for land use land cover classification in Southern New Caledonia / G. Rousset, M. Despinoy, K. Schindler, M. Mangeas // Remote Sensing. 2021. Vol. 13(12), pp. 2257. DOI: 10.3390/rs13122257
7. Intensity and stationarity analysis of land use change based on CART algorithm / X. Sang, Q. Guo, X. Wu et al. // Scientific Reports. 2019. Vol. 9(1), pp. 12279. DOI: 10.1038/s41598-019-48586-3
8. Pixel-vs. Object-based landsat 8 data classification in Google Earth Engine using random forest: The case study of maiella national park / A. Tassi, D. Gigante, G. Modica et al. // Remote Sensing. 2021. Vol. 13(12), pp. 2299. DOI: 10.3390/rs13122299
9. Мониторинг и прогноз динамики наземного покрова Среднего Поволжья по спутниковым данным в QGIS MOLUSCE / О.Н. Воробьев, Э.А. Курбанов, Д. Ша и др. // Современные проблемы дистанционного зондирования Земли из космоса. 2023. Т. 20, № 5. С. 176–193. DOI: 10.21046/2070-7401-2023-20-5-176-193.
10. Review of image classification algorithms based on convolutional neural networks / L. Chen, S. Li, Q. Bai et al. // Remote Sensing. 2021. Vol. 13 (22), pp. 4712. DOI: 10.3390/rs13224712
11. Dobrinić D., Gašparović M., Medak D. Sentinel-1 and 2 Time-series for vegetation mapping using random forest classification: a case study of Northern Croatia // Remote Sensing. 2021. Vol. 13 (12), pp. 2321. DOI: 10.3390/rs13122321
12. Mustaqim M., Islam W. Assessment of land use /land cover changes and its future predictions using CA-Markov with ANN simulation for Berhampore, West Bengal, India. 2023. DOI: 10.21203/rs.3.rs-3407386/v1
13. Мониторинг лесного покрова водоохраных зон рек Марий Эл по спутниковым данным / Л.В. Тарасова, Э.А. Курбанов, О.Н. Воробьев и др. // Современные проблемы дистанционного зондирования Земли из космоса. 2024. Т. 21, № 2. С. 177–195. DOI: 10.21046/2070-7401-2024-21-2-177-195
14. Effects of canopy and multi-epoch observations on single-point positioning errors of a GNSS in coniferous and broadleaved forests / T. Feng, S. Chen, Z. Feng et al. // Remote Sensing. 2021. Vol. 13(12), pp. 2325. DOI: 10.3390/rs13122325
15. Orfeo ToolBox: open source processing of remote sensing images / M. Grizonnet, J. Michel, V. Pouchon et al. // Open Geospatial Data, Software and Standards. 2017. Vol. 2 (15), pp. 8. DOI: 10.1186/s40965-017-0031-6
16. Transformer meets convolution: A bilateral awareness network for semantic segmentation of very fine resolution urban scene images / L. Wang, R. Li, D. Wang et al. // Remote Sensing. 2021. Vol. 13(16), pp. 3065. DOI: 10.3390/rs13163065
17. Yang X., Zheng X.Q., Lv L.N. A spatiotemporal model of land use change based on ant colony optimization, Markov chain and cellular automata // Ecological Modelling. 2012. Vol. 233, pp. 11–19. DOI: 10.1016/j.ecolmodel.2012.03.011
18. Раевский Б.В., Тарасенко В.В. Изучение динамики лесных массивов Карельской части Зеленого пояса Фенноскандии методами дистанционного зондирования // Труды Карельского научного центра РАН № 4. 2019. С. 89–99. DOI: 10.17076/them1023
19. Фотограмметрия и дистанционное зондирование: учебное пособие / А.А. Калинин, А.М. Бондаренко, М.Н. Семенов и др. Зерноград: Азово-Черноморский инженерный институт ФГБОУ ВО «Донской ГАУ», 2017. 98 с. [Электронный ресурс]. Режим доступа: Локальная сеть Библиотеки Азово-Черноморского инженерного института ФГБОУ ВО Донской ГАУ.

20. Тематическое дешифрирование и интерпретация космических снимков среднего и высокого пространственного: учебное пособие разрешения / А.Н. Шихов, А.П. Герасимов, А.И. Пономарчук, Е.С. Перминова. Пермь: Пермский государственный национальный исследовательский университет, 2020. 191 с. [Электронный ресурс]. URL: <http://www.psu.ru/files/docs/science/books/uchebnie-posobiya/shikhov-gerasimov-ponomarchuk-perminova-tematicheskoe-deshifrovanie-i-interpretaciya-kosmicheskikh-snimkov.pdf> (дата обращения 20.09.2024).

21. Репозиторий плагинов QGIS Python. Плагин dzetsaka [Электронный ресурс]. URL: <https://plugins.qgis.org/plugins/dzetsaka/#plugin-about> (дата обращения 20.09.2024).

22. Pirsgys 0.4.1 [Электронный ресурс]. URL: <https://pypi.org/project/pyrsgis/> (дата обращения 20.09.2024).

23. Scikit-learn: машинное обучение в Python / Fabian Pedregosa et al.; 2011. Vol. 12(85), pp. 2825–2830, [Электронный ресурс]. URL: <https://jmlr.csail.mit.edu/papers/v12/pedregosa11a.html> (дата обращения 20.09.2024).

References

1. Bartalev S.A., Egorov V.A., Zharko V.O., Dupyan E.A., Plotnikov D.E., Khvostikov S.A. [State and prospects of development of methods of satellite mapping of vegetation cover of Russia]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa* [Modern Problems of Earth Remote Sensing from Space], 2015, vol. 12, no. 5, pp. 203–221. (in Russ.)

2. Elsakov V.V., Shchanov V.M. [Current changes in the vegetation cover of reindeer pastures in the Timan tundra based on the results of satellite imagery data analysis]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa* [Modern Problems of Earth Remote Sensing from Space], 2019, vol. 16, no. 2, pp. 128–142. (in Russ.) DOI: 10.21046/2070-7401-2019-16-2-128-142

3. Levankov A.N., Dudkin A.A. [Neural Network Identification of Unused Agricultural Land in QGIS Remote Sensing Imagery]. In: *BIG DATA and Advanced Analytics = BIG DATA i analiz vysokogo urovnya: sbornik nauchnykh statey VII Mezhdunarodnoy nauchno-prakticheskoy konferentsii, Minsk, 19–20 maya 2021 goda* [BIG DATA and advanced analytics = BIG DATA and high-level analytics: collection of scientific articles of the VII International Scientific and Practical Conference, Minsk, May 19–20, 2021]. Minsk, pp. 102–109. (in Russ.) Available at: <https://libelidoc.bsuir.by/handle/123456789/43890> (accessed 20 September 2024)

4. Fazzini P., De Felice Proia G., Adamo M., Blonda P., Petracchini F., Forte L., Tarantino C. Sentinel-2 remote sensed image classification with patchwise trained ConvNets for grassland habitat discrimination. *Remote Sensing*, 2021, vol. 13(12), pp. 2276. DOI: 10.3390/rs13122276

5. Kaganga L.S., Ngogo N.M. (2024). Impact of land use and land cover changes on ecosystem services value in Mwanza city, Tanzania. *Asian Journal of Environment & Ecology*, vol. 23(5), pp. 30–40. DOI: 10.9734/ajee/2024/v23i5545

6. Rousset G., Despinoy M., Schindler K., Mangeas M. Assessment of deep learning techniques for land use land cover classification in Southern New Caledonia. *Remote Sensing*, 2021, vol.13(12), pp. 2257. DOI: 10.3390/rs13122257

7. Sang X., Guo Q., Wu X. et al. Intensity and stationarity analysis of land use change based on CART algorithm. *Scientific Reports*, 2019, vol. 9(1), pp. 12279. DOI: 10.1038/s41598-019-48586-3

8. Tassi A., Gigante D., Modica G., Di Martino L., Vizzari M. Pixel-vs. Object-based landsat 8 data classification in Google Earth Engine using random forest: The case study of maiella national park. *Remote Sensing*, 2021, vol. 13(12), pp. 2299. DOI: 10.3390/rs13122299

9. Vorob'ev O.N., Kurbanov E.A., Sha D., Lezhnin S.A., Van D., Dergunov D.M. [Monitoring and forecasting of land cover dynamics in the Middle Volga region using satellite data in QGIS MOLUSCE]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa* [Modern Problems of Earth Remote Sensing from Space], 2023, vol. 20, no. 5, pp. 176–193. DOI: 10.21046/2070-7401-2023-20-5-176-193 (in Russ.)

10. Chen L., Li S., Bai Q., Yang J., Jiang S., Miao Y. Review of image classification algorithms based on convolutional neural networks. *Remote Sensing*, 2021, vol. 13(22), pp. 4712. DOI: 10.3390/rs13224712

11. Dobričić D., Gašparović M., Medak D. Sentinel-1 and 2 Time-series for vegetation mapping using random forest classification: a case study of Northern Croatia. *Remote Sensing*, 2021, vol. 13(12), pp. 2321. DOI: 10.3390/rs13122321

12. Mustaqim M., Islam W. Assessment of land use /land cover changes and its future predictions using CA-Markov with ANN simulation for Berhampore, West Bengal, India. 2023. DOI: 10.21203/rs.3.rs-3407386/v1

13. Tarasova L.V., Kurbanov E.A., Vorob'ev O.N., Bu Kh., Lezhnin S.A., Dergunov D.M. [Monitoring of forest cover of water protection zones of rivers in Mari El using satellite data]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa* [Modern Problems of Earth Remote Sensing from Space], 2024, vol. 21, no. 2, pp. 177–195. (in Russ.) DOI: 10.21046/2070-7401-2024-21-2-177-195

14. Feng T., Chen S., Feng Z., Shen C., Tian Y. Effects of canopy and multi-epoch observations on single-point positioning errors of a GNSS in coniferous and broadleaved forests. *Remote Sensing*, 2021, vol. 13(12), pp. 2325. DOI: 10.3390/rs13122325
15. Grizonnet M., Michel J., Poughon V. et al. Orfeo ToolBox: open source processing of remote sensing images. *Open Geospatial Data, Software and Standards*, 2017, vol. 2(15), pp. 8. DOI: 10.1186/s40965-017-0031-6
16. Wang L., Li R., Wang D., Duan C., Wang T., Meng X. Transformer meets convolution: A bilateral awareness network for semantic segmentation of very fine resolution urban scene images. *Remote Sensing*, 2021, vol. 13(16), pp. 3065. DOI: 10.3390/rs13163065
17. Yang X., Zheng X.Q., Lv L.N. A spatiotemporal model of land use change based on ant colony optimization, Markov chain and cellular automata. *Ecological Modelling*, 2012, vol. 233, pp. 11–19. DOI: 10.1016/j.ecolmodel.2012.03.011
18. Raevskiy B.V., Tarasenko V.V. [Study of forest dynamics in the Karelian part of the Fennoscandia green belt by remote sensing methods]. *Trudy Karelskogo nauchnogo tsentra Rossiyskoy Akademii Nauk* [Proceedings of the Karelian Scientific Centre of the Russian Academy of Sciences], 2019, no. 4, pp. 89–99. (in Russ.) DOI: 10.17076/them1023
19. Kalinin A.A., Bondarenko A.M., Sementsov M.N., Strogiiy B.N., Kazatchkov I.A., Matveikina J.V., Samoylova T.F. *Fotogrammetriya i distantsionnoe zondirovanie: uchebnoe posobie* [Photogrammetry and remote sensing: textbook]. Zernograd, 2017. 98 p. [Electronic resource]. (in Russ.)
20. Shikhov A.N., Gerasimov A.P., Ponomarchuk A.I., Perminova E.S. *Tematicheskoe deshifirovanie i interpretatsiya kosmicheskikh snimkov srednego i vysokogo prostranstvennogo razresheniya: uchebnoe posobie* [Thematic interpretation and interpretation of medium and high spatial resolution space images: textbook]. Perm, 2020. 191 p. [Electronic resource]. (in Russ.) Available at: <http://www.psu.ru/files/docs/science/books/uchebnie-posobiya/shikhov-gerasimov-ponomarchuk-perminova-tematicheskoe-deshifirovanie-i-interpretatsiya-kosmicheskikh-snimkov.pdf> (accessed 20 September 2024)
21. QGIS Python Plugin Repository. Dzetsaka Plugin [Electronic resource]. Available at: <https://plugins.qgis.org/plugins/dzetsaka/#plugin-about> (accessed 20 September 2024)
22. Pirsgys 0.4.1 [Electronic resource]. Available at: <https://pypi.org/project/pyrsgis/> (accessed 20 September 2024)
23. Scikit-learn: machine learning in Python / Fabian Pedregosa et al.; 12(85):2825–2830, 2011. [Electronic resource]. Available at: <https://jmlr.csail.mit.edu/papers/v12/pedregosa11a.html> (accessed 20 September 2024)

Информация об авторах:

Попов Евгений Владимирович, доктор технических наук, профессор, профессор кафедры инженерной графики и информационного моделирования, Нижегородский государственный архитектурно-строительный университет, Нижний Новгород, Россия; popov_eugene@list.ru.

Юрченко Павел Вадимович, аспирант кафедры инженерной графики и информационного моделирования, ассистент кафедры геоинформатики, геодезии и кадастра, Нижегородский государственный архитектурно-строительный университет, Нижний Новгород, Россия; pavel-yurchenko@list.ru

Information about the authors:

Evgeniy V. Popov, Doctor of Engineering Sciences, Professor of the Department of Engineering Graphics and Information Modeling, Nizhny Novgorod State University of Architecture and Civil Engineering, Nizhny Novgorod, Russia; popov_eugene@list.ru

Pavel V. Yurchenko, postgraduate student of the Department of Engineering Graphics and Information Modeling, Nizhny Novgorod State University of Architecture and Civil Engineering, Nizhny Novgorod, Russia; pavel-yurchenko@list.ru

Статья поступила в редакцию 26.02.2025, принята к публикации 03.03.2025.

The article was submitted 26.02.2025, approved after reviewing 03.03.2025.