УДК 378:004
DOI: 10.25686/978-5-8158-2474-4-2025-466-471

Применение искусственного интеллекта для визуализации контуров природных объектов на спутниковых снимках

Е. В. Попов, П. В. Юрченко
Нижегородский государственный архитектурно-строительный университет, Нижний Новгород, Россия

Аннотация. Авторами изучено применение методов машинного обучения для классификации изображений на спутниковых снимках. Для визуализации контуров природных объектов был применен нейросетевой алгоритм. При подготовке обучающего набора данных использовались методы машинного обучения. Проведён анализ полученных результатов классификации и дана оценка точности алгоритма, предложены способы его усовершенствования.

***Ключевые слова*:** геометрическое моделирование, геоинформационное моделирование, нейросеть, природные ресурсы, визуализация границ объектов, классификация изображений

Using artificial intelligence to visualize the contours of natural objects in satellite images

E. V. Popov, P. V. Yurchenko
Nizhny Novgorod State University of Architecture and Civil Engineering, Nizhny Novgorod, Russia

Abstract. The authors studied the application of machine learning methods for image classification in satellite images. A neural network algorithm was used to visualize the contours of natural objects. Machine learning methods were used to prepare the training dataset. The classification results were analyzed, and the accuracy of the algorithm was evaluated. Suggestions were made for improving the algorithm.

***Keywords*:** geometric modeling, geoinformation modeling, neural network, natural resources, visualization of object boundaries, image classification.

Введение

Спутниковые снимки сегодня являются одним их часто применяемых материалов для изучения природных объектов. Анализ спутниковых снимков проводится с целью распознавания на них природных объектов или объектов антропогенного происхождения и использования полученных данных для аналитики и прогноза. Инструментами в этих исследованиях, как правило, выступают технологии искусственного интеллекта, основанные на методах машинного обучения и компьютерного зрения.

Применение возможностей искусственного интеллекта в совокупности с геоинформационными технологиями позволяет решить несколько важных взаимосвязанных задач. Во-первых, визуализировать контуры изучаемых объектов на спутниковом снимке, а во-вторых, при регулярных наблюдениях накапливать материал для аналитики и прогноза возможных изменений в контурах и площадях целевых объектов, используя только рабочее место за компьютером. Так можно наблюдать за изменениями в контурах целевых объектов в течение определенного периода времени, и при накоплении необходимого количества данных прогнозировать дальнейшее развитие территории. Качественный прогноз является важным для принятия решений в управлении как конкретными ресурсами, так и всей территорией исследования.

Вопросам исследования возможностей искусственного интеллекта в процессе распознавания природных и антропогенных объектов на спутниковых снимках, при котором визуально выделяются их контуры и занимаемые ими площади, в последнее десятилетие посвящают свои исследования многие российские и зарубежные ученые. Ряд из них сосредоточены на максимально достоверном распознавании и визуализации изучаемых объектов и их автоматизированной категоризации и типизации. Применяемые методы машинного обучения исследователи, как правило, сочетают между собой, часто используя как основной метод для комбинирования – нейронную сеть. Так, использование нейросети глубокого обучения U-Net в сочетании с семантической нейросетью ES-Net при изучении состояния лесных массивов описано в [1]; использование временных рядов и многомасштабной географически взвешенной регрессионной модели (MGWR), данные для которой распознаются с

помощью метода случайного леса на спутниковых снимках в исследовании сельскохозяйственных культур рассмотрено в [2]. Иные исследования посвящены прогнозированию развития ситуации с изменениями контуров изучаемых объектов. Основными предметами изучения являются природные объекты – лесные массивы, земли сельскохозяйственного назначения и культивируемые на них насаждения, водотоки и водоемы, прибрежные зоны рек, морей и океанов. Так, исследование [3] посвящено прогнозу развития сельскохозяйственных культур, в частности, пшеницы, и использует при этом пять различных алгоритмов машинного обучения (Random Forest, Gradient Boosting, AdaBoost, LightGBM и XGBoost); делая вывод об их производительности, наиболее успешной считает модель XGBoost. Вместе с тем использование данных из нескольких источников в сочетании с алгоритмами машинного обучения повышает точность прогнозирования и добавляет новые возможности в системы поддержки принятия решений в сельском хозяйстве. Подобный вывод делается в исследовании [4], где применяются методы оценки малых площадей, статистические регрессионные методы в совокупности с данными, полученными из открытых источников – спутник Landset 8, платформа Google Earth Engine при исследовании качества лесных массивов.

Для представляемого исследования были выбраны природные объекты, расположенные на территории Большеболдинского округа Нижегородской области и представляющие существенную ценность для данной территории – лесные массивы. Значимость данных природных объектов и применяемые методы делают исследование актуальным и востребованным.

Постановка задачи

Известно, что при изучении объектов, занимающих на поверхности Земли значительные по площади территории, используют данные дистанционного зондирования. К таким объектам, безусловно, относятся и лесные массивы [5]. Чаще всего их можно получить из материалов спутниковых снимков, данных аэрофотосъемки, а также снимков, сделанных с помощью беспилотных летательных аппаратов. Поскольку последние два источника съемки требуют специфических инструментов и не всегда возможны для свободного доступа, было решено использовать материалы хранилищ спутниковых снимков, доступные широкому кругу пользователей. Из существующих открытых источников были отобраны снимки исследуемой территории за период с 2014 по 2024 год, сделанные спутниками Landset 8 и 9 в период вегетации (с мая по сентябрь) в хорошую ясную и безоблачную погоду, так как таким снимкам требовалось меньше предварительных процедур обработки, и их можно было использовать для создания геоинформационной модели, позволяющей визуализировать на растровом снимке контуры изучаемых объектов.

Обработанные в геоинформационных системах данные дистанционного зондирования земной поверхности, полученные со спутниковых снимков, позволяют работать как со всеми природными ресурсами региона, так и сосредоточиться на отдельных, наиболее важных объектах. Для этой работы требовался достаточно эффективный и относительно несложный алгоритм, позволяющий проводить распознавание изображений исследуемых природных объектов на спутниковых снимках, визуализировать их контуры и использовать полученные результаты для дальнейших решений.

Теория

1. Особенности изучаемых объектов

Лесные массивы относятся к категории объектов, не имеющих типичных контуров, что подтверждается визуальным анализом выбранных для исследования фрагментов спутниковых снимков (рис. 1). Это затрудняет распознавание и визуализацию их контуров на спутниковых снимках методами широко распространенных в последнее время сверточных нейронных сетей (CNN). По нашему мнению, использование классического нейросетевого алгоритма «с учителем», имеющего в базе метод обратного распространения ошибки, для распознавания изображений лесных массивов является более приемлемым. Здесь мы учитывали также и требование к экономии ресурсов при разработке и внедрении алгоритма.

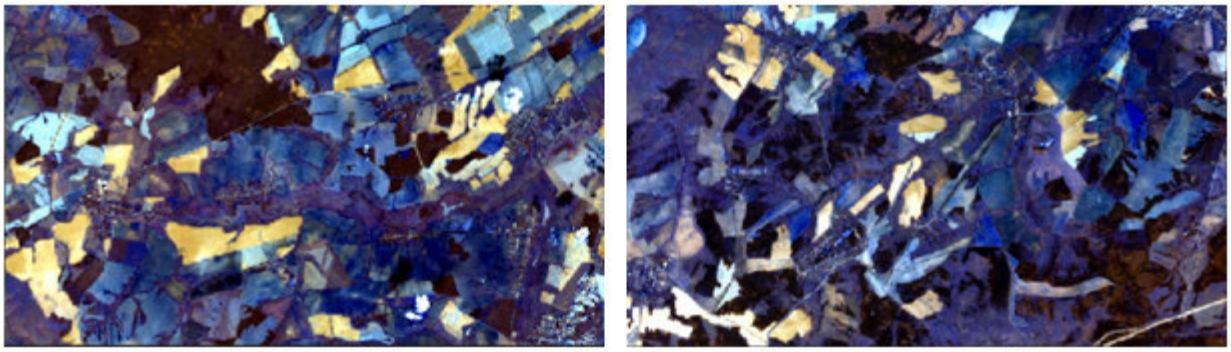

Рис. 1. Фрагменты веекторных слоев снимка с лесными массивами: *а*) – фрагмент *1*; *б*) – фрагмент *2*

2. Основные этапы работы по визуализации лесных массивов

Следующие этапы работы с выбранными снимками в рамках рассматриваемого подхода предполагали применение геоинформационных технологий и проводились в геоинформационной системе QGIS:

– сборка растрового снимка с помощью модуля GDAL Tools;
– выделение сцен снимка, содержащих исследуемую территорию;
– отделение фрагментов сцен, содержащих лесные массивы;
– моделирование лесных массивов с помощью плагинов QGIS [6];
– получение размеченного одноканального растра с изображениями лесных массивов.

При сборке снимка были взяты данные каналов с 1 по 7 и объединены в виртуальной среде GDAL Tools QGIS. Затем на выделенных фрагментах снимка, содержащих лесные массивы, были добавлены векторные слои для осуществления разметки и классификации изображений лесных массивов, используя эталонные полигоны.

В рамках проводимого исследования визуализация изображений лесных массивов означает проведение дихотомической классификации выбранного фрагмента сцены спутникового снимка, посредством которой были получены одноканальные растры с пикселями двух типов: относящиеся к лесным массивам и не относящиеся к таковым. Эта классификация осуществлялась с помощью основного метода исследования – нейросетевого алгоритма. Обучающие наборы данных для него были подготовлены с помощью четырех известных алгоритмов машинного обучения – Gaussian Mixture Model, Random Forest, Support Vector Machines, K-Nearest Neighbors, реализованных в QGIS посредством встроенных плагинов [6]. После подготовки наборов данных и обучения нейросети были произведены распознавание и визуализация контуров лесных массивов на выбранных фрагментах спутниковых снимков. Результаты визуализации лесных массивов нейросетевым алгоритмом приведены для фрагмента 1 (рис. 2) и фрагмента 2 (рис. 3) с обучающими наборами, подготовленными каждым из упомянутых методов.

Необходимо заметить, что на предыдущих этапах исследования, описанного в [7], в нейросетевом алгоритме использовалось 14 входных узлов и две функции активации ReLu и Softmax, так как требовалось реализовать дихотомическую классификацию. Сеть была реализована на языке программирования Python, были применены функции библиотек numpy, pirsgis, tensorflow. Однако при попытке внедрить алгоритм в открытые геоинформационные системы QGIS (ГИС QGIS) было обнаружено, что не все версии QGIS позволяют корректно его запустить. Поэтому алгоритм был изменен для устранения этих проблем следующим образом: для повышения точности взяты 64 узла и те же функции активации, применяемые библиотеки Python – numpy, pirsgis, scikit-learn. А это позволит использовать его в перспективе как плагин для открытой ГИС QGIS, что расширит возможности его применения и может представлять определенную новизну в проводимом исследовании.

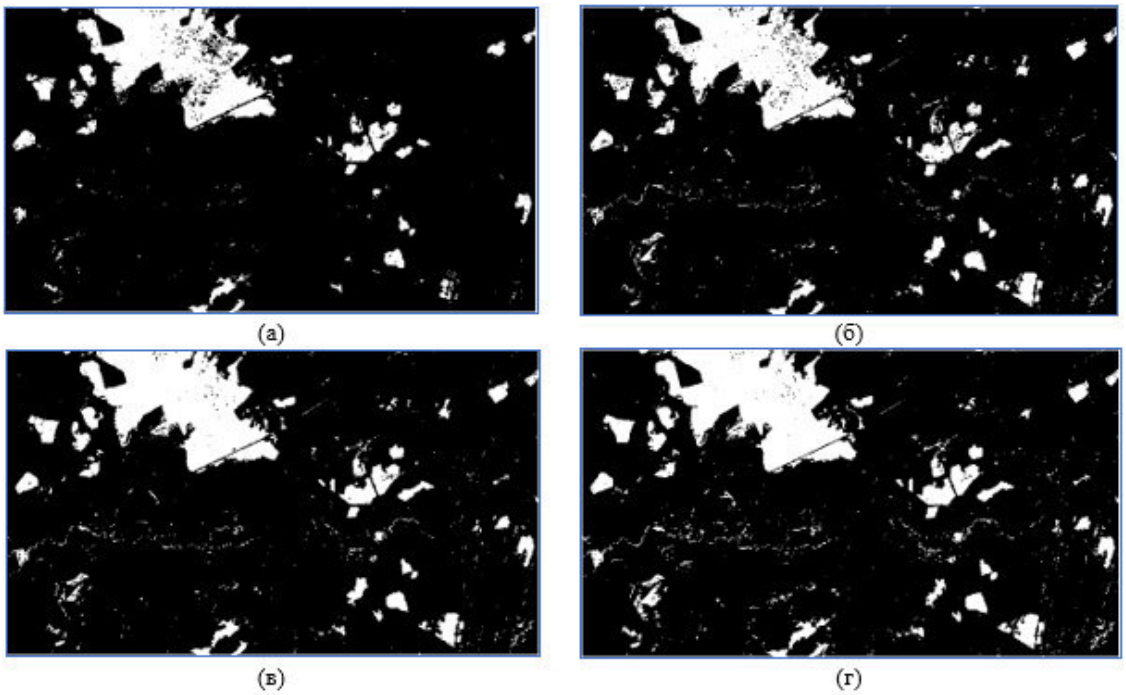

Рис. 2. Визуализация лесных массивов на фрагменте 1 с обучающими наборами, подготовленными методами: *а*) Gaussian Mixture Model; *б*) K-Nearest Neighbors; *в*) Random Forest; *г*) Support Vector Machines

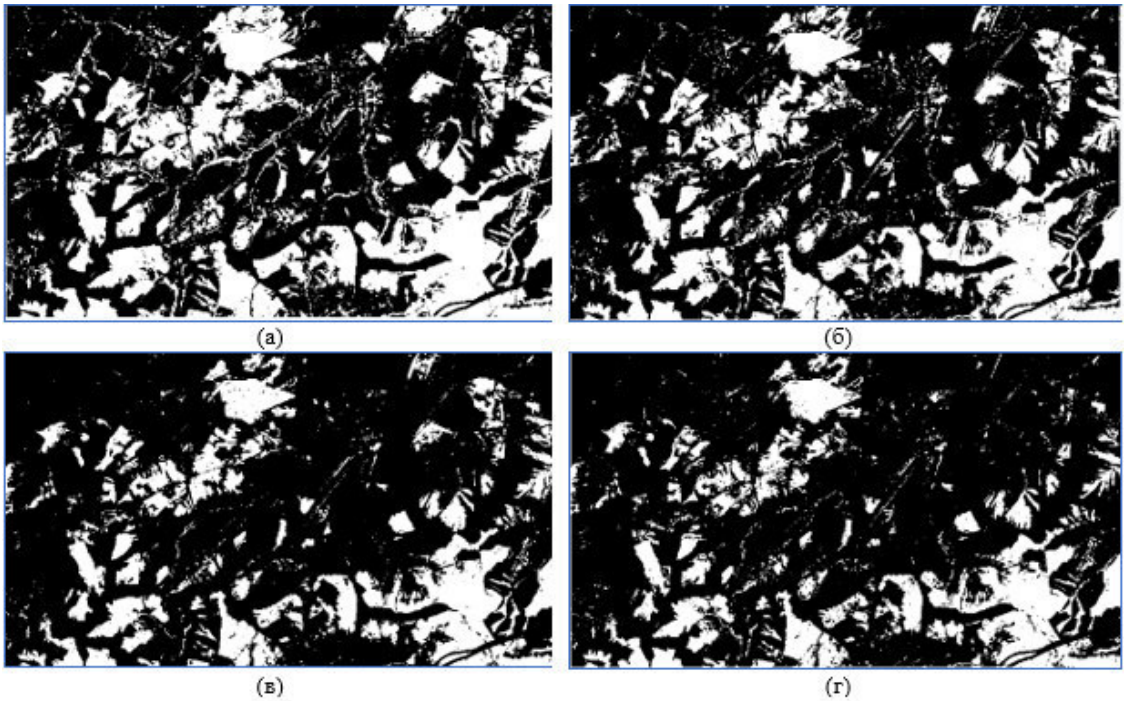

Рис. 3. Визуализация лесных массивов на фрагменте 2 с обучающими наборами, подготовленными методами: *а*) Gaussian Mixture Model; *б*) K-Nearest Neighbors; *в*) Random Forest; *г*) Support Vector Machines

Результаты экспериментов

После обучения с применением наборов данных, подготовленных с помощью указанных методов машинного обучения, нейросеть показала в целом приемлемые результаты матрицы ошибок и соответствующих метрик – точности (precision), полноты (recall) и общей метрики (accuracy). Это позволяет считать предсказанные значения визуализации удовлетворительными и свидетельствующими о достижении поставленных целей.

Данные матриц ошибок для визуализации изображений лесных массивов на фрагменте 1 приведены в таблице 1, на фрагменте 2 – в таблице 2. Из данных таблиц следует, что фрагмент с большим

количеством лесных массивов распознается так же эффективно и достоверно, как и фрагмент, на котором лесных массивов не так много, что позволяет сделать вывод о независимости алгоритма от количества пикселей распознаваемых объектов.

Таблица 1. **Данные матрицы ошибок для фрагмента 1**

Метод подготовки обучающего набора	TN	FN	FP	TP
GMM	17657	115	299	5629
KNN	17747	427	104	5422
RendF	17371	122	516	5691
SVM	17243	268	263	5926

Таблица 2. **Данные матрицы ошибок для фрагмента 2**

Метод подготовки обучающего набора	TN	FN	FP	TP
GMM	17276	33	680	5711
KNN	17567	180	180	5669
RendF	17792	523	95	5290
SVM	17264	268	242	5926

Обсуждение результатов

Рассчитанные на базе приведенных в таблицах 1, 2 показателей матриц ошибок метрики позволяются говорить о достаточной точности и успешности нейросетевого алгоритма с каждым из подготовленых наборов данных. Вместе с тем можно говорить о более или менее успешных запусках алгоритма с некоторыми из обучающих наборов и также о наборе, который наиболее стабильно работает в сочетании с разработанным нейросетевым алгоритмом. Как видно из рисунка 4, наиболее стабильно работает алгоритм с обучающим набором данных, подготовленным с применением метода опорных векторов (SVM).

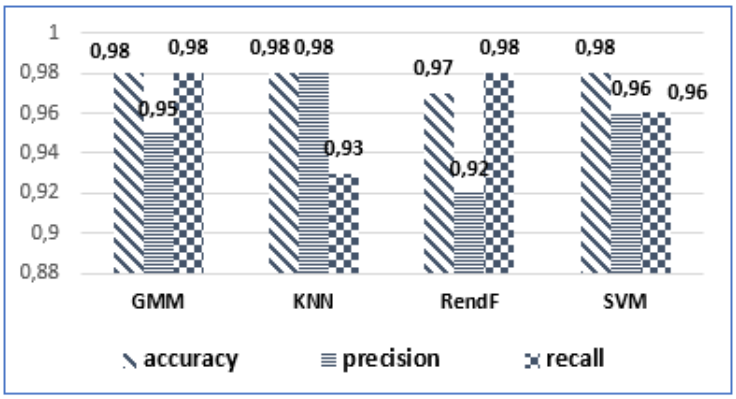

(а)

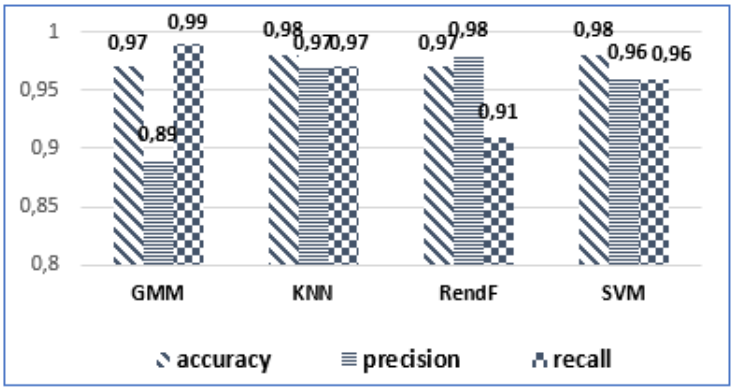

(б)

Рис. 4. Визуализация значений метрик нейросетевого алгоритма: *а*) фрагмент 1; *б*) фрагмент 2

Показатели метрик нейросети более высокие по сравнению с описанными в [7], они варьируются в диапазонах: accuracy 0,97-0,98, precision 0,91-0,98, recall 0,93-0,98.

Заключение

На данном этапе исследования сделан вывод о том, что автоматизированные способы распознавания объектов на спутниковых снимках требуют более тщательной подготовки исходных данных. В частности, обучающий набор данных может быть подготовлен с помощью алгоритмов машинного обучения. Тогда в результате будет получена более точная геоинформационная модель исследуемой территории, визуализирующая контуры и площади изучаемых объектов.

Список литературы

1. Wang, Y., Zhang, Z., Xia, J., Zhao, F., & Dong, P. (2025). ES-Net Empowers Forest Disturbance Monitoring: Edge–Semantic Collaborative Network for Canopy Gap Mapping. *Remote Sensing*, *17*(14), 2427. https://doi.org/10.3390/rs17142427.

2. Xiao, P., Zhou, Y., Qian, J., Liu, Y., & Li, X. (2025). Spatiotemporal Mapping and Driving Mechanism of Crop Planting Patterns on the Jianghan Plain Based on Multisource Remote Sensing Fusion and Sample Migration. *Remote Sensing*, *17*(14), 2417. https://doi.org/10.3390/rs17142417.

3. Rufaioğlu, S. B., Bilgili, A. V., Savaşlı, E., Özberk, İ., Aydemir, S., Ismael, A. M., Kaya, Y., & Matos-Carvalho, J. P. (2025). Sensor-Based Yield Prediction in Durum Wheat Under Semi-Arid Conditions Using Machine Learning Across Zadoks Growth Stages. *Remote Sensing*, *17*(14), 2416. https://doi.org/10.3390/rs17142416.

4. Alegbeleye, O. M., Poudel, K. P., VanderSchaaf, C., & Yang, Y. (2025). Improving the Estimates of County-Level Forest Attributes Using GEDI and Landsat-Derived Auxiliary Information in Fay–Herriot Models. *Remote Sensing*, *17*(14), 2407. https://doi.org/10.3390/rs17142407.

5. Габитова А.А. Дистанционное зондирование и ГИС в оценке лесозарастания неиспользуемых сельскохозяйственных земель // Успехи современного естествознания. 2022. № 11. С. 42-46. Режим доступа: https://natural-sciences.ru/ru/article/view?id=37926.

6. Репозиторий плагинов QGIS Python. Плагин dzetsaka. Режим доступа: https://plugins.qgis.org/plugins/dzetsaka/#plugin-about.

7. Попов Е.В., Юрченко П.В. Использование нейросети для геометрического моделирования природных и антропогенных объектов // Приволжский научный журнал. 2024. № 4. С.336-341.