



УДК 004.8

DOI 10.52575/2712-7443-2024-48-4-526-541

## Применение геопространственного искусственного интеллекта для классификации изображений дистанционного зондирования

Каличкин В.К., Гарафутдинова Л.В., Федоров Д.С.

Сибирский федеральный научный центр агробиотехнологий Российской академии наук  
Россия, 630501, Новосибирская область, р.п. Краснообск, ул. Центральная, 26  
E-mail: lv.garafutdinova@mail.ru

**Аннотация.** В последние годы геопространственный искусственный интеллект стал неотъемлемым инструментом в анализе и интерпретации изображений дистанционного зондирования. Данная работа исследует применение методов геопространственного искусственного интеллекта для эффективной классификации изображений дистанционного зондирования. Традиционные подходы к обработке изображений часто сталкиваются с ограничениями, связанными с вариабельностью состояния объектов, качеством данных и объемами информации. Использование алгоритмов машинного обучения и глубокого обучения позволяет преодолеть эти препятствия, обеспечивая более точные и надежные результаты. Для классификации пространственных объектов использовали космические снимки *Sentinel-2* с мая по апрель территории землепользования фермерского хозяйства (ФХ) Новосибирской области с пространственным разрешением 10 м в пикселе. Сегментацию изображений проводили в программном обеспечении *SAGA GIS*. Для машинного обучения использовали методы – *Random Forest (RF)*, *Extreme Gradient Boosting (XGBoost)* и многослойный перцептрон (*MLP*). Среди всех моделей *MLP* показала наилучшие результаты с точностью 95,20 % и высоким значением коэффициента Каппа Козна, тогда как модели *RF* и *XGBoost* показали 85,0 %. Это делает модель *MLP* оптимальным выбором, особенно когда важна высокая точность классификации.

**Ключевые слова:** геопространственный искусственный интеллект, дистанционное зондирование, машинное обучение, сегментация, классификация

**Для цитирования:** Каличкин В.К., Гарафутдинова Л.В., Федоров Д.С. 2024. Применение геопространственного искусственного интеллекта для классификации изображений дистанционного зондирования. Региональные геосистемы, 48(4): 526–541. DOI: 10.52575/2712-7443-2024-48-4-526-541

---

## The Use of Geospatial AI for Remote Sensing Image Classification

Vladimir K. Kalichkin, Lyudmila V. Garafutdinova, Dmitry S. Fedorov

Siberian Federal Scientific Centre of AgroBioTechnologies of the Russian Academy of Sciences,  
2b Tsentralnaya St, Novosibirsk Region, Krasnoobsk 630501, Russia  
E-mail: lv.garafutdinova@mail.ru

**Abstract.** In recent years, geospatial artificial intelligence has become an integral tool in the analysis and interpretation of remote sensing images. This work explores the application of geospatial artificial intelligence methods for effective classification of remote sensing images. Traditional image processing approaches often face limitations related to object state variability, data quality, and information volume. The use of machine learning and deep learning algorithms allows overcoming these obstacles, providing more accurate and reliable results. For the classification of spatial objects, Sentinel-2 satellite images of the areas used by the Novosibirsk region farms taken from May to April were used, with a spatial resolution of 10 m per pixel. Image segmentation was performed using SAGA GIS software. For machine

learning, Random Forest (RF), Extreme Gradient Boosting (XGBoost), and Multilayer Perceptron (MLP) methods were used. Among all models, MLP showed the best results with the accuracy of 95.20 % and a high Cohen's Kappa coefficient, while RF and XGBoost models showed 85.0 %. This makes the MLP model an optimal choice, especially when a high classification accuracy is important.

**Keywords:** geospatial artificial intelligence, remote sensing, machine learning, segmentation, classification

**For citation:** Kalichkin V.K., Garafutdinova L.V., Fedorov D.S. 2024. The Use of Geospatial AI for Remote Sensing Image Classification. *Regional Geosystems*, 48(4): 526–541. DOI: 10.52575/2712-7443-2024-48-4-526-541

## Введение

Классификация изображений земных объектов с помощью дистанционного зондирования – сложный процесс, требующий учета многих признаков. Основные этапы классификации изображений включают предварительную обработку изображений (сегментация), определение подходящей системы классификации, извлечение признаков, выбор обучающих данных и оценку точности [Mehmood et al., 2022]. Интеграция дистанционного зондирования, географических информационных систем (ГИС) и искусственного интеллекта (ИИ) стала перспективным направлением исследований в этой предметной области [Колесников, 2022; Janga et al., 2023]. Эффективное использование множества характеристик данных дистанционного зондирования и выбор подходящего метода классификации особенно важны для повышения ее точности.

ГИС становятся все более популярными в различных областях, таких как управление окружающей средой, транспорт, сельское хозяйство и др. Данные ГИС фиксируют местоположения наблюдений или объектов Земли, их связанные атрибуты и пространственные отношения, которые существуют между такими наблюдениями и объектами. ГИС позволяют собирать, анализировать и визуализировать географические данные, тем самым способствуют принятию решений на основе пространственных закономерностей и взаимосвязей. Однако объем этих данных увеличивается высокими темпами и традиционные методы ГИС сталкиваются с проблемами их обработки и анализа. Например, по данным *NASA Earth Science Data Systems (ESDS)*, облако *Earthdata* содержало более 59 петабайт данных о Земле по состоянию на сентябрь 2021 года. По оценкам *ESDS*, ожидается, что это количество увеличится до более чем 148 ПБ в 2023 году, 205 ПБ в 2024 и 250 ПБ в 2025 году (<https://www.earthdata.nasa.gov/eosdis/cloud-evolution>). С целью решения этой проблемы, в том числе в сельском хозяйстве, получило развитие направление под термином «геопространственный искусственный интеллект» (англ. *Geospatial Artificial Intelligence – GeoAI*) [Li, Hsu, 2022; Sagan et al., 2024].

Геопространственный искусственный интеллект – это использование ИИ, включая машинное обучение (МО) и глубокое обучение (ГО), интегрированное с ГИС, для получения знаний посредством классификации изображений и анализа пространственных данных [Ekeanyanwu et al., 2022; Choi, 2023]. ИИ предполагает разработку интеллектуальных машин, которые могут выполнять задачи, обычно требующие человеческого интеллекта. МО фокусируется на разработке алгоритмов, которые позволяют машинам учиться на данных, и используется для выполнения классификации изображений, обогащения данных кластеризацией и моделирования пространственных отношений в ГИС [Якушев и др., 2022; Radočaj, Jurišić, 2022]. Обучение обычно происходит с участием человека, при этом необходимо предварительно помечать данные, чтобы алгоритм понимал характерные признаки каждого типа земной поверхности и мог их использовать для автоматической идентификации этих типов на других изображениях. Хорошо известными алгоритмами МО для классификации изображений дистанционного зондирования являются метод случайного леса (*Random*



*Forest – RF*), экстремальный градиентный бустинг (*eXtreme Gradient Boosting – XGBoost*) и метод опорных векторов (*Support Vector Machines – SVM*) [Zhang et al., 2022; Choi, 2023]. Случайный лес включает в себя пакетирование, создание ансамбля деревьев решений путем случайного выбора объектов из обучающих данных. Комбинируя несколько деревьев принятия решений, *RF*-классификаторы могут обеспечивать надежные прогнозы, предлагая измерения переменной важности [Basheer et al., 2022]. Подобно *RF*, метод *XGBoost* также использует деревья решений в качестве базовых средств обучения, но продвигает процесс дальше, объединяя сильные стороны отдельных деревьев в технике бустинга [Nalluri et al., 2020]. Другим традиционным методом являются *SVM*, который классифицирует данные путем обнаружения многомерных гиперплоскостей и эффективно разделяет отдельные классы, что, однако, не всегда сопровождается лучшей классификацией, чем при использовании *RF* [Adugna et al., 2022].

ГО является подразделом МО, которое использует нейронные сети для обработки больших и сложных наборов данных. В отличие от МО в моделях ГО участие человека ограничивается подготовкой данных, выбором признаков и модели, ее архитектуры и др. Входные данные анализируются через различные слои сети, причем каждый слой определяет конкретные характеристики и закономерности в этих данных [Vali et al., 2020]. Например, если необходимо идентифицировать такие объекты, как растительность и дороги, модель ГО может обучаться с помощью изображений различных типов растительности и дорог, обрабатывая эти изображения через слои внутри нейронной сети, а затем находит идентификаторы, необходимые для классификации вышеупомянутых объектов. Однако модели на основе нейронных сетей считаются моделями «черного ящика» и поэтому сложны для понимания причин, лежащих в основе их классификации и прогноза [Carabantes, 2020]. В рамках развития парадигмы *GEOBIA* разработано большое количество моделей интеграции машинного обучения с ГИС, в том числе искусственных нейронных сетей различной архитектуры и размера, обладающих разной эффективностью классификации [Chen et al., 2018; Johnson, Ma, 2020; Фомина, 2023; Ezzahouani et al., 2023].

В целом существует множество различных моделей классификации, однако утверждать, что есть лучшая для всех изображений не представляется возможным, поскольку эффективность моделей зависит от исходных данных и конечного применения. Вопросы тематической обработки (интерпретации) данных дистанционного зондирования непосредственно связаны с проблемой выбора адекватных алгоритмов классификации [Асмус и др., 2018]. В предыдущей работе авторов [Гарафутдинова и др., 2024] были протестированы два алгоритма машинного обучения (*SVM* и *RF*) с общей точностью классификации объектов землепользования 78,4 % и 82,3 %, соответственно. В данной работе предпринята попытка увеличить эффективность моделей классификации изображений с помощью применения методологии геопространственного искусственного интеллекта.

Цель исследований – разработать интегрированные с ГИС модели МО и ГО, способствующие повышению точности классификации изображений дистанционного зондирования.

### Объекты и методы исследований

Исследования выполнены на территории землепользования фермерского хозяйства (ФХ) в Искитимском районе Новосибирской области, расположенного в центральной лесостепной подзоне (54°22'37.64" с.ш., 82°47'18.73" в.д.) с общей площадью 28759 га. Территория ФХ в основном представляет сильно изрезанную многочисленными логами и балками равнину с абсолютными отметками над уровнем моря от 206 до 278 м. В почвенном покрове преобладают серые лесные, черноземы выщелоченный и луговые почвы.

Для сегментации и классификации объектов внутрихозяйственного землепользования использованы многозональные космические снимки *Sentinel-2* с пространственным разрешением 10 м в пикселе за апрель – начало мая 2023 года, скаченные с *Sentinelhub*

(<https://www.sentinel-hub.com>). Из 13 спектральных каналов *Sentinel-2* в работе использовали три полосы видимого диапазона (*RGB*) – красный (*B02*), зеленый (*B03*), синий (*B04*) и инфракрасный (*B08*).

Предварительная обработка изображений проведена с помощью программного продукта *SAGA GIS* версии 8.5.1 с открытым исходным кодом и состояла из радиометрической коррекции для устранения варьирования значений яркости пикселей; атмосферной коррекции – для определения расположения диапазонов съемки за счет окон прозрачности; геометрической коррекции, которая включала исправление искажений снимка (полосчатость, выпадение строк), а также геокодирование – привязывание каждой точки изображения к координате соответствующей точки на местности.

Сегментацию изображения проводили с использованием объектно-ориентированного алгоритма «*Object Based Image Segmentation*» (*OBIS*). Алгоритм *OBIS* в *SAGA GIS* позволяет объединить несколько модулей в один процесс автоматизированной сегментации изображений. Теоретическая основа алгоритма описана в работе [Hossain, Chen, 2019].

Формирование вектора признаков для каждого пикселя осуществляли на основе информации, извлеченной из многозонального изображения дистанционного зондирования. К вектору признаков относили яркость и текстуру по каждому спектральному каналу. Извлечение текстурных характеристик из растровых данных осуществляли с помощью функции *r.texture* в *GRASS GIS*, применяемой через интерфейс *QGIS*.

Выбор обучающих данных и формирование выборки для классификации выполняли посредством экспертного анализа сегментов, где признаки выбирали таким образом, чтобы их изменения в пределах каждого сегмента были малы, а между сегментами – велики. К признакам предъявляли требования устойчивости, нечувствительности к искажениям, вращению и поддержанию различия классов. Исходная выборка состояла из 3938 сегментов. Из них 196 были присвоены классы (1 – пашня; 2 – растительность; 3 – лес, лесополоса; 4 – застройка; 5 – водоемы), которые были разделены на обучающую и тестовую выборки в соотношении 80 и 20 % соответственно.

Классификацию полученных объектов осуществляли с использованием алгоритмов машинного обучения – случайный лес (*Random Forest – RF*), экстремальный градиентный бустинг (*Extreme Gradient Boosting – XGBoost*) и нейронная сеть с архитектурой многослойного персептрона (*Multilayer Perceptron – MLP*) в *SAGA GIS*, а также с использованием языка программирования *Python* в интерактивном блокноте *Jupyter*.

*RF* представляет собой ансамблевый метод, объединяющий множество деревьев решений. Каждое дерево обучается на случайной подвыборке исходных данных и признаков [Breiman, 2001]. Эффективность *RF* достигается за счет агрегации «слабых» классификаторов, что снижает риск переобучения и повышает обобщающую способность модели. *XGBoost* – усовершенствованная реализация градиентного бустинга, оптимизированная для высокой производительности и точности. Алгоритм использует параллельную обработку для построения деревьев решений, применяет регуляризацию для предотвращения переобучения и использует оптимизированную структуру данных для эффективного поиска разбиений [Chen, Guestrin, 2016; Nalluri et al., 2020]. *MLP* – тип искусственной нейронной сети прямого распространения, состоящий из входного слоя, одного или нескольких скрытых слоев и выходного слоя [Alom et al., 2019]. *MLP* позволяет моделировать сложные нелинейные зависимости в данных. Каждый нейрон в скрытых слоях использует нелинейную функцию активации.

Оценку точности полученных результатов проводили с помощью матрицы путаницы (*confusion matrix*) и коэффициента Каппа Коэна.

Матрица путаницы представляет собой таблицу, которая показывает соотношение между предсказанными и истинными классами. Она позволяет визуализировать производительность модели классификации, отображая количество правильных и неправильных предсказаний для каждого класса.

Коэффициент Каппа Коэна ( $\kappa$ ) – это статистическая мера согласованности между наблюдаемой и ожидаемой точностью классификации. Он учитывает возможность случайного согласия и поэтому считается более надежным показателем, чем простая точность. Значения  $\kappa$  варьируются от  $-1$  до  $1$ , где  $1$  означает полное согласие,  $0$  – случайное согласие, а отрицательные значения указывают на согласие хуже, чем случайное. Коэффициент Каппа рассчитывается по формуле:

$$\kappa = \frac{p_o - p_e}{1 - p_e}, \quad (1)$$

где  $p_o$  – наблюдаемая согласованность (точность), а  $p_e$  – ожидаемая согласованность [Zarf et al., 2016].

Отображение полученных результатов в виде карты выполнено с использованием программного продукта с открытым исходным кодом *QuantumGIS (QGIS)* (<https://qgis.org/ru/site/>) в привязанной к международной геодезической системе координат *WGS 84*.

### Результаты и их обсуждение

Для анализа пространственных объектов идеально подходит ГИС, потому что она предназначена для хранения, обработки, поиска, распространения и представления пространственной информации. Кроме того, ГИС является также программным средством. Поэтому ГИС дает возможность для оперативного внедрения возможностей ИИ в рамках исследовательской деятельности. Например, в программных продуктах *ArcGIS*, *SAGA GIS* и *QGIS* разработаны модули, основанные на современных алгоритмах для принятия решений и анализа данных. Модули включают в себя инструментарий, позволяющий реализовать модели МО путем включения пространственных данных и выполнять классификацию объектов дистанционного зондирования. С другой стороны, данные дистанционного зондирования имеют пространственную привязку, то есть они расположены в географическом пространстве. Координаты каждого пикселя однозначно определены, что облегчает поступление информации о пикселях из векторных слоев ГИС.

Сегментация изображений является первым шагом в распознавании многозональных космических снимков и включает в себя разделение изображения на относительно однородные области, т. е. «сегменты изображения» или «объекты изображения». Семантическая сегментация происходит, когда каждый пиксель в изображении классифицируется как принадлежащий какому-то сегменту. В ГИС это часто называют классификацией пикселей или сегментацией изображений и используют для создания карт, например, землепользования. Сегментация экземпляра – это более точный метод обнаружения объектов, в котором рисуется граница каждого экземпляра объекта. Общая сегментация сочетает в себе как семантическую сегментацию, так и сегментацию экземпляров. Эти сегменты изображения служат базовой единицей для дальнейшего анализа, например, классификации изображений или обнаружения изменений, с использованием спектральных/пространственных/контекстных атрибутов сегментов [Johnson, Ma, 2020].

При использовании алгоритма *OBIS* группировка пикселей в сегменты происходила посредством итеративного процесса. Значение ширины полосы пропускания для генерации сегментов выбиралась экспертным способом в соответствии с размером исследуемой области и пространственным разрешением космического снимка. В нашем случае ширина полосы пропускания, или размер, необходимый для генерации исходной точки в процессе сегментации объектов, определяет масштаб области, в которой осуществляется анализ и выделение сегмента. Это происходит на основе спектральных или иных характеристик, и этот размер установлен равным 10. В результате сегментации на основе анализа отражательной способности объектов многозонального космического изображения территории ФХ размером 1632 x 1188 пикселей было сформировано 3938 сегментов (рис. 1).

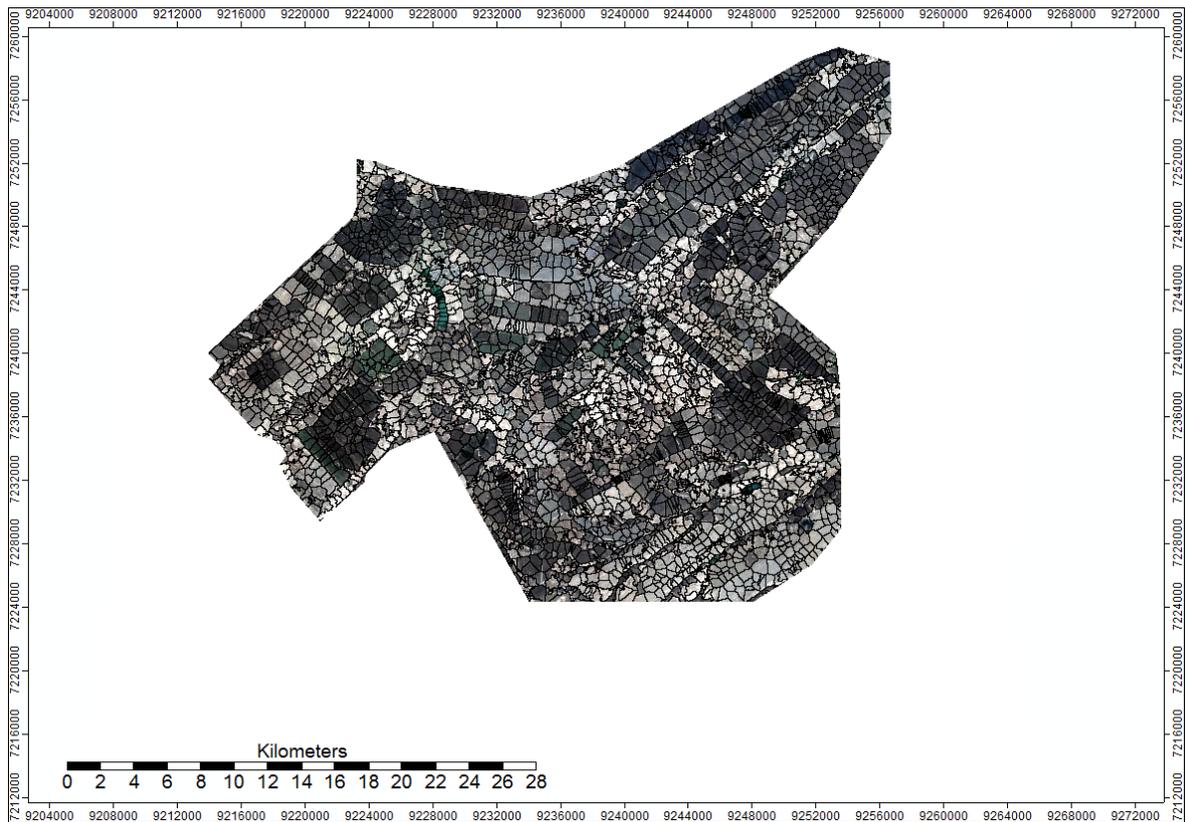


Рис. 1. Сегментация территории ФХ  
Fig. 1. Segmentation of the farm territory

Объектно-ориентированный подход извлечения классов объектов является рабочим процессом, поддерживаемым инструментами, охватывающими три основные функциональные области: сегментацию изображения, получение аналитической информации о сегментах и классификацию. Выходные данные одного инструмента являются входными данными для последующих инструментов, где цель заключается в создании значимой объектно-ориентированной карты классов объектов. Объектно-ориентированный процесс похож на традиционный процесс классификации пиксельного изображения, использующий методы контролируемой и неконтролируемой классификации. Вместо того, чтобы классифицировать пиксели, процесс классифицирует сегменты.

Для классификации изображений дистанционного зондирования в ходе исследования применили три метода машинного обучения. Для каждого метода проведен подбор оптимальных параметров с использованием методов кросс-валидации и поиска по сетке параметров, что позволило максимизировать производительность моделей.

При построении модели *RF* было проанализировано использование различного количества деревьев с оценкой ошибки *out-of-bag* (*OOB*) для каждой конфигурации (рис. 2а) и максимальной глубины дерева с оценкой точности (рис. 2б). *OOB* ошибка рассчитывается на основе наблюдений, не вошедших в обучающую выборку конкретного дерева, что позволяет получить несмещенную оценку ошибки обобщения модели. Оптимальное количество деревьев было установлено равным 32, что обеспечило баланс между точностью модели и вычислительной эффективностью. Анализ влияния максимальной глубины дерева показал, что наибольшая точность модели (0,85) достигается при глубине 6, после чего наблюдается постепенное снижение точности.

Для оптимизации алгоритма *XGBoost* осуществляли подбор гиперпараметров, используя метод перекрестной проверки и сетку параметров (рис. 3). Были протестированы различные

комбинации скорости обучения (0,01, 0,1, 0,3), максимальной глубины дерева (3, 6, 9), минимального веса листа (1, 3, 5) и количества итераций (5, 15, 50, 100, 200, 300).

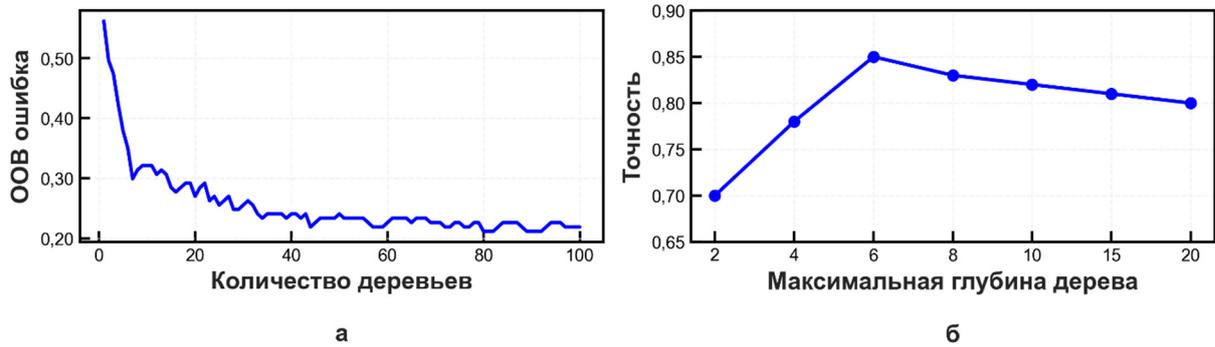


Рис. 2. Результаты подбора параметров модели RF: а) график зависимости *OOB* ошибки от количества деревьев; б) график зависимости точности модели от максимальной глубины дерева  
 Fig. 2. Results of RF model parameter tuning: а) plot of the *OOB* error versus number of trees; б) plot of the model accuracy versus maximum tree depth

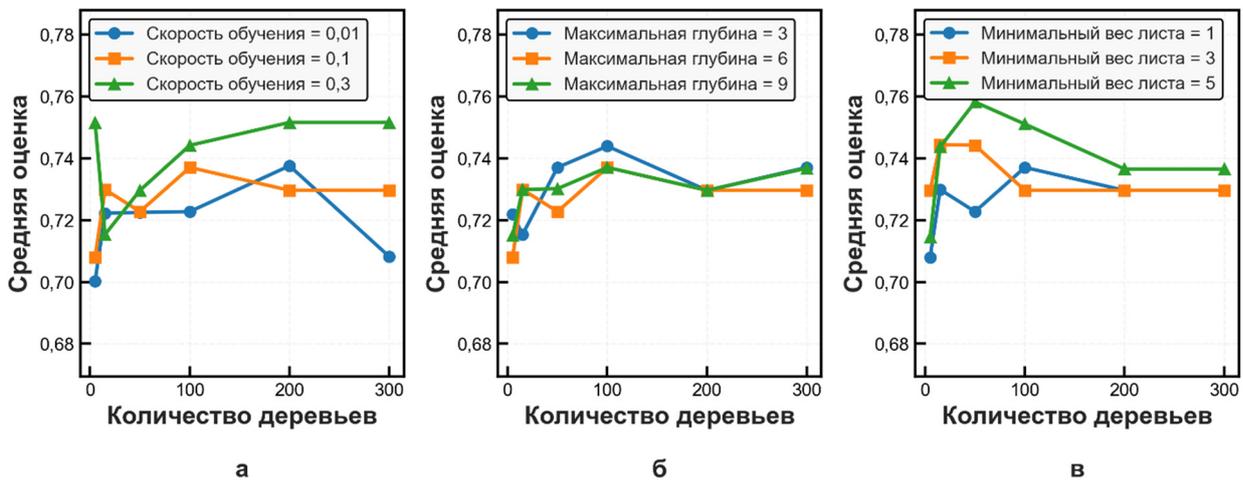


Рис. 3. Результаты подбора гиперпараметров для *XGBoost*: а) влияние скорости обучения; б) влияние максимальной глубины дерева; в) влияние минимального веса листа  
 Fig. 3. Results of hyperparameter tuning for *XGBoost*: а) learning rate effect; б) maximum depth effect; в) minimum child weight effect

При анализе влияния скорости обучения (рис. 3а) наблюдалось, что при скорости 0,01 модель демонстрировала постепенное улучшение производительности с увеличением количества деревьев. Средняя оценка возрастала с 0,70 при 5 деревьях до 0,74 при 300 деревьях. При скорости обучения 0,1 наблюдалось более быстрое улучшение производительности на начальных этапах, с достижением оценки 0,73 уже при 50 деревьях и последующей стабилизацией результатов. Скорость обучения 0,3 показала наиболее высокую начальную производительность (0,75) при малом количестве деревьев, с последующими колебаниями в диапазоне 0,73–0,76.

Исследование влияния максимальной глубины дерева (рис. 3б) показало, что при глубине 3 модель демонстрировала стабильную производительность с постепенным улучшением до 0,75. Увеличение глубины до 6 и 9 не приводило к значительному улучшению результатов, но могло вызывать большую вариативность оценок.

Анализ влияния минимального веса листа (рис. 3в) выявил, что значение 1 обеспечивало наиболее стабильные результаты, тогда как увеличение до 3 и

5 приводило к более выраженным колебаниям производительности модели, хотя и позволяло достигать несколько более высоких максимальных значений (до 0,76).

Отметим, что даже при небольшом количестве деревьев (5–15) модель достигала достаточно высокой производительности, особенно при более высоких скоростях обучения. Оптимальные результаты (точность модели составила 0,85) были получены при использовании 50–100 деревьев, скорости обучения 0,3, максимальной глубине 6 и минимальном весе листа 1, что обеспечивало баланс между точностью модели и вычислительной эффективностью.

С целью оптимизации работы *MLP* были проведены эксперименты с различными архитектурами с помощью варьирования количеством скрытых слоев и числом нейронов в них. В качестве функции активации использовали *ReLU (Rectified Linear Unit)*, которая помогает преодолеть проблему затухающих градиентов и ускоряет сходимость. Для оптимизации параметров модели применяли алгоритм *Adam*, сочетающий преимущества адаптивного градиентного спуска и метода моментов. Для предотвращения переобучения были использованы методы регуляризации, включая *L2*-регуляризацию, ограничивающую веса нейронов, и *dropout*, случайно отключающий часть нейронов во время обучения. Эти техники повышают обобщающую способность модели и помогают избежать чрезмерной подгонки под обучающие данные.

Результаты сравнения производительности различных конфигураций *MLP* представлены на рис. 4, где показаны значения среднеквадратичной ошибки (*MSE*) и точности для каждой архитектуры.

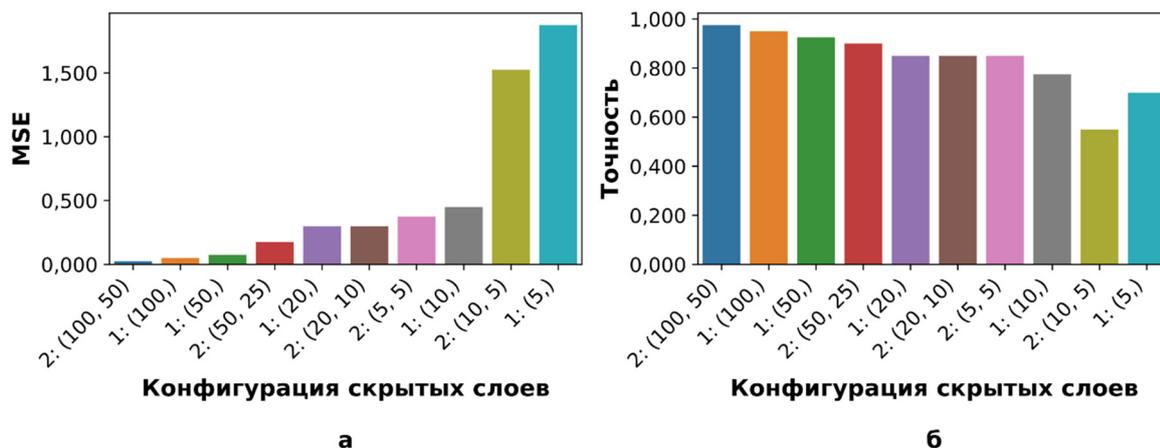


Рис. 4. Сравнение производительности различных конфигураций многослойного персептрона MLP: а) оценка по средней абсолютной ошибке; б) оценка по точности  
Fig. 4. Performance comparison of various configurations of the multilayer perceptron (MLP): а) evaluation by mean absolute error; б) evaluation by accuracy

Наилучшую производительность показала модель с двумя скрытыми слоями, содержащими 100 и 50 нейронов соответственно. Эта архитектура достигла наименьшего значения *MSE* (0,025) и наивысшей точности (0,952). Это говорит о том, что для данной задачи относительно сложная архитектура с достаточным количеством нейронов оказалась наиболее эффективной. Отметим, что модели с одним скрытым слоем также показали высокую производительность. Конфигурации со 100 и 50 нейронами в одном слое достигли точности 0,95 и 0,925 соответственно, что лишь немного уступало лучшей двухслойной модели. Увеличение или уменьшение числа нейронов не всегда приводило к улучшению результатов. Например, модели с меньшим количеством нейронов (5 и 10) в одном слое показали значительно худшую производительность (*MSE*: 1,875 и 0,45, точность: 0,7 и 0,775 соответственно) по сравнению с оптимальными моделями. Это подчеркивает важ-

ность выбора достаточного количества нейронов для решения данной задачи. Архитектуры с двумя скрытыми слоями показали смешанные результаты. Некоторые из них (например, «2 слоя: (50 и 25 нейронов)») достигли хороших показателей, сравнимые с лучшими однослойными моделями. Однако конфигурации с меньшим количеством нейронов, такие как «(5, 5)» и «(10, 5)», показали относительно низкую производительность, что еще раз подчеркивает важность правильного выбора архитектуры и количества нейронов.

В целом результаты моделирования показали, что для данной задачи эффективны как однослойные, так и двухслойные архитектуры с достаточным количеством нейронов (50–100). При этом наилучший результат достигался при использовании двухслойной архитектуры с большим количеством нейронов.

После обучения всех трех моделей был проведен сравнительный анализ их эффективности. Для этого были использованы матрица путаницы и коэффициент Каппа Коэна. Результаты представлены в таблице и на рис. 5.

Сравнение моделей по коэффициенту Каппа Коэна  
 Comparison of models by Cohen's Kappa coefficient

Метод	Нижнее значение к	Среднее значение к	Верхнее значение к
RF	0,66	0,79	0,86
XGBoost	0,72	0,78	0,85
MLP	0,76	0,89	0,94



Рис. 5. Матрицы путаницы: а) модель *XGBoost*; б) модель *RF*; в) модель *MLP*  
 Fig. 5. Confusion matrices: а) *XGBoost* model; б) *RF* model; в) *MLP* model

Модель *MLP* показала наилучшие результаты среди всех рассмотренных моделей, достигнув точности 0,952 % и самого высокого среднего значения коэффициента Каппа Коэна. Этот результат указывает на способность нейронных сетей эффективно улавливать сложные нелинейные взаимосвязи в данных. Модель *MLP* также продемонстрировала наиболее стабильную производительность, о чем свидетельствует широкий диапазон верхнего значения коэффициента Каппа (0,94).

Модели *XGBoost* и *RF* показали одинаковую точность, равную 85,0 %, что ниже, чем у *MLP*. Средние значения коэффициента Каппа у этих алгоритмов также близки. Это говорит о том, что оба метода демонстрируют схожую способность учитывать случайное согласие между предсказаниями и фактическими значениями.

Несмотря на более низкие показатели по сравнению с *MLP*, модели *XGBoost* и *RF* также могут быть классифицированы как надежные и эффективные методы. Учитывая более высокую интерпретируемость этих алгоритмов по сравнению с «черным ящиком» нейронных сетей, они могут быть предпочтительным выбором в ситуациях, где важно понимание процесса принятия решений моделью. Модель *RF*, имея несколько более широкий диапазон значений коэффициента Каппа (от 0,66 до 0,86), может быть особенно полезна в сценариях, требующих высокой интерпретируемости результата или при работе с ограниченными объемами данных.

Стоит отметить, что все три модели продемонстрировали достаточно высокие показатели эффективности, что свидетельствует об их применимости к данной задаче классификации. Однако модель *MLP* явно выделялась более высокой точностью и стабильностью, что делает ее наиболее предпочтительным выбором для данной задачи, особенно когда приоритетом является максимальная точность классификации.

Анализ матрицы путаницы показал, что все три модели (*RF*, *XGBoost* и *MLP*) имеют схожую структуру ошибок, но с некоторыми существенными различиями в производительности для разных классов. Модель *MLP* продемонстрировала наилучшую производительность, безошибочно классифицировав все 18 образцов первого класса, а также все образцы третьего (9), четвертого (2) и пятого (4) классов. Единственные ошибки модель *MLP* допустила во втором классе, правильно классифицировав 4 из 7 образцов. Модели *RF* и *XGBoost* показали идентичные результаты, что может указывать на схожесть их подходов к решению данной задачи. Обе эти модели правильно классифицировали 16 из 18 образцов первого класса, 4 из 7 образцов второго класса, 8 из 9 образцов третьего класса, и безошибочно определили все образцы четвертого (2) и пятого (4) классов.

Анализ *ROC*-кривых и соответствующих метрик (рис. 6) предоставляет дополнительное подтверждение превосходства модели *MLP*. Нейронная сеть продемонстрировала наивысшие показатели как по метрике *AUC* (площадь под *ROC*-кривой), так и по *F1*-метрике. Микроусредненный *AUC* для *MLP* составил 0,97, что превышает показатели *Random Forest* (0,95) и *XGBoost* (0,90). Аналогичное улучшение наблюдается и в значениях *F1*-метрики, где *MLP* достигла микроусредненного показателя 0,85, в то время как *Random Forest* и *XGBoost* показали 0,76 и 0,75 соответственно.

Анализ метрик по отдельным классам показывает, что все модели достигли максимальной эффективности ( $AUC = 1,00$ ) для пятого класса. Однако для других классов наблюдаются существенные различия. *MLP* демонстрирует более стабильные и высокие показатели по всем классам, с особенно заметным преимуществом в классификации первого класса ( $AUC = 0,99$ ) и второго класса ( $AUC = 0,87$ ). Модели *Random Forest* и *XGBoost* показали более низкие результаты для второго класса ( $AUC = 0,81$  и  $0,73$  соответственно), что согласуется с результатами анализа матриц путаницы.

Эти результаты свидетельствуют о том, что модель *MLP* значительно превосходит другие модели в классификации большинства классов, особенно первого и третьего. Такая разница в производительности может быть обусловлена способностью *MLP* лучше улавливать сложные нелинейные взаимосвязи в данных, что особенно важно для точной классификации. Однако следует отметить, что модели *RF* и *XGBoost*, хотя и уступали *MLP* в общей точности, показывали стабильные результаты среди различных классов.

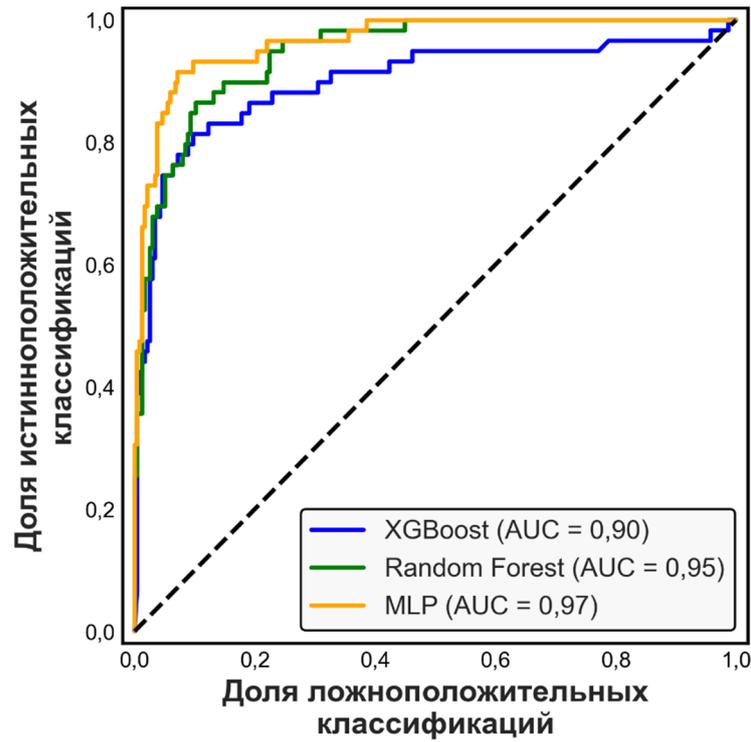


Рис. 6. ROC-кривые для моделей *Random Forest*, *XGBoost* и *MLP*  
Fig. 6. ROC curves for *Random Forest*, *XGBoost* and *MLP* models

На основании результатов классификации изображения дистанционного зондирования с помощью модели *MLP* создана карта землепользования ФХ, содержащая пять идентифицированных классов пространственных объектов (рис. 7).

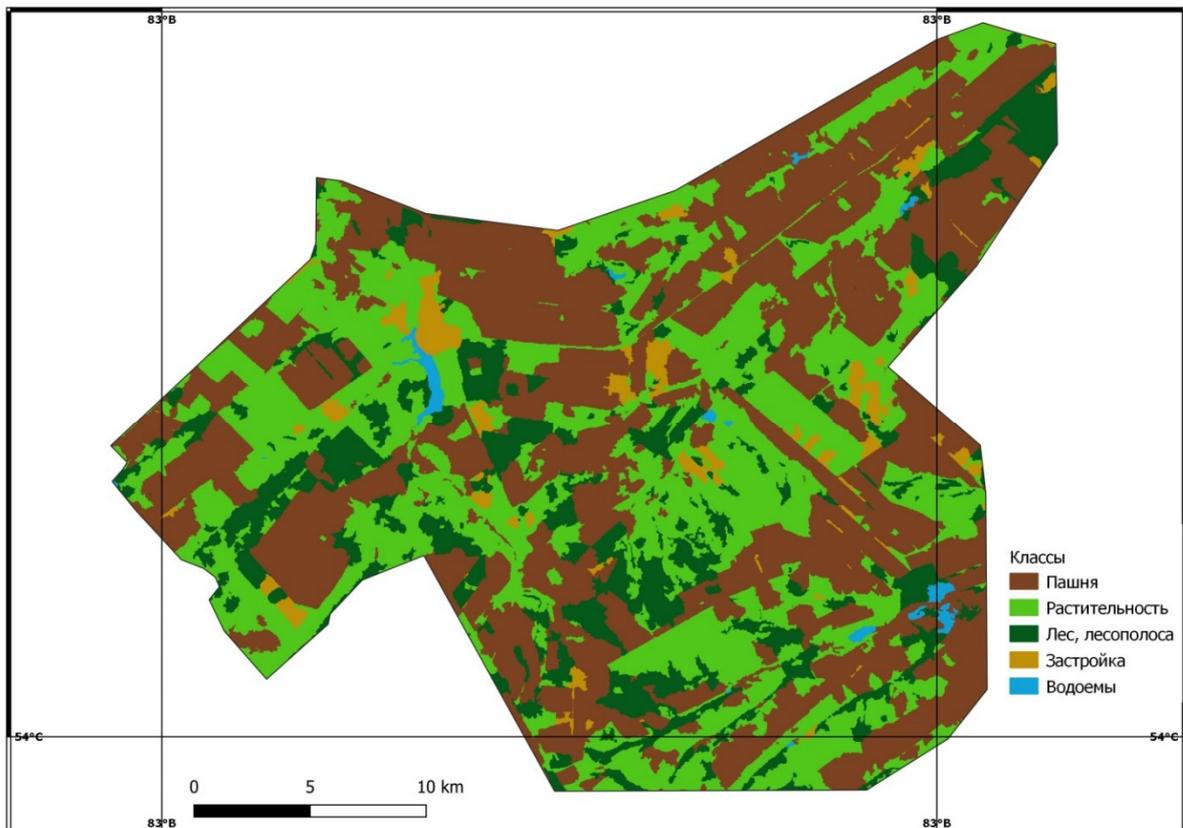


Рис. 7. Карта классов объектов территории землепользования ФХ, полученная с помощью *MLP*  
Fig. 7. Land-use class map of the farm territory, obtained using *MLP*

В рамках нашего исследования выбранные классификаторы выступали как эффективные инструменты для отличия пяти ключевых классов, используя данные дистанционного зондирования, полученные за апрель – май. Небольшое количество изображений также играет важную роль в исключении необходимости в больших объемах данных, что позволяет избежать трудностей, связанных с предварительной обработкой и анализом изображений в те моменты, когда требуется принимать решения, поддерживающие программы и внедрение актуальных инструментов управления земельными ресурсами.

### Заключение

В ходе проведенного исследования с целью классификации пространственных объектов на изображении дистанционного зондирования конкретного землепользования с помощью объектно-ориентированного алгоритма *OBIS* в *SAGA GIS* проведена сегментация, выявлена аналитическая информация о сегментах и проведена их классификация. Для классификации изображений дистанционного зондирования применяли методы МО – *RF*, *XGBoost*, и ГО – *MLP*.

Для каждой модели проведен подбор оптимальных параметров с использованием методов кросс-валидации и поиска по сетке параметров, что позволило максимизировать их производительность. При построении модели *RF* с помощью оценки ошибки *out-of-bag* (*OOB*) было установлено оптимальное количество деревьев, равное 32, что обеспечило баланс между точностью модели и вычислительной эффективностью. Для модели *XGBoost* наилучшие результаты достигались при большем количестве деревьев (50–300) и средней или высокой скорости обучения (0,1–0,3). Модель *MLP* показала наилучшую производительность с двумя скрытыми слоями, содержащими 100 и 50 нейронов соответственно. Эта архитектура достигла наименьшего значения *MSE* и наивысшей точности.

Модель *MLP* показала наилучшие результаты среди всех рассмотренных моделей, достигнув точности 95,20 % и самого высокого среднего значения коэффициента Каппа Коэна. Модели *RF* и *XGBoost* уступали *MLP* в точности (85,0 %), однако, учитывая более высокую интерпретируемость этих алгоритмов по сравнению с «черным ящиком» нейронных сетей, они могут быть предпочтительным выбором в ситуациях, где важно понимание процесса принятия решений моделью.

Анализ матрицы путаницы показал, что *MLP* значительно превосходила другие модели в классификации большинства классов, особенно первого и третьего. Такая разница в производительности может быть обусловлена способностью *MLP* лучше улавливать сложные нелинейные взаимосвязи в данных.

Все протестированные модели продемонстрировали достаточно высокие показатели эффективности, что свидетельствует об их применимости к данной задаче классификации. Однако модель *MLP* явно выделялась точностью и стабильностью, что делает ее наиболее предпочтительным выбором, особенно когда приоритетом является максимальная точность классификации.

### Список литературы

- Асмус В.В., Бучнев А.А., Кровотынцев В.А., Пяткин В.П., Салов Г.И. 2018. Комплекс программного обеспечения *PlanetaMonitoring* в прикладных задачах дистанционного зондирования. *Автометрия*, 54(3): 14–23. <https://doi.org/10.15372/AUT20180302>.
- Гарафутдинова Л.В., Каличкин В.К., Федоров Д.С. 2024. Объектно ориентированная классификация изображений дистанционного зондирования Земли с использованием машинного обучения. *Вестник НГАУ (Новосибирский государственный аграрный университет)*, 2: 37–47. <https://doi.org/10.31677/2072-6724-2024-71-2-37-47>.
- Колесников А.А. 2022. Анализ методов и средств искусственного интеллекта для анализа и интерпретации данных активного дистанционного зондирования. *Вестник СГУГиТ*



- (Сибирского государственного университета геосистем и технологий), 27(3): 74–94. <https://doi.org/10.33764/2411-1759-2022-27-3-74-94>.
- Фомина Е.С. 2023. Оценка эффективности применения специализированных нейронных сетей для повышения разрешения изображений, получаемых при дистанционном зондировании Земли. Системы управления, связи и безопасности, 3: 71–90. <https://doi.org/10.24412/2410-9916-2023-3-71-90>.
- Якушев В.П., Захарян Ю.Г., Блохина С.Ю. 2022. Состояние и перспективы использования дистанционного зондирования Земли в сельском хозяйстве. Современные проблемы дистанционного зондирования Земли из космоса, 19(1): 287–294. <https://doi.org/10.21046/2070-7401-2022-19-1-287-294>.
- Alom M.Z., Taha T.M., Yakopcic Ch., Westberg S., Sidike P., Nasrin M.S., Hasan M., Van Essen B.C., Awwal A.A.S., Asari V.K. 2019. A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics*, 8(3): 292. <https://doi.org/10.3390/electronics8030292>.
- Adugna T., Xu W., Fan J. 2022. Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote Sensing*, 14(3): 574. <https://doi.org/10.3390/rs14030574>.
- Basheer S., Wang X., Farooque A.A., Nawaz R.A., Liu K., Adekanmbi T., Liu S. 2022. Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing*, 14(19): 4978. <https://doi.org/10.3390/rs14194978>.
- Breiman L. 2001. Random Forests. *Machine Learning*, 45: 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Carabantes M. 2020. Black-Box Artificial Intelligence: an Epistemological and Critical Analysis. *AI & Society*, 35: 309–317. <https://doi.org/10.1007/s00146-019-00888-w>.
- Chen T., Guestrin C. 2016. Xgboost: A Scalable Tree Boosting System. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>.
- Chen G., Weng Q., Hay G.J., He Y. 2018. Geographic Object-Based Image Analysis (GEOBIA): Emerging Trends and Future Opportunities. *GIScience & Remote Sensing*, 55(2): 159–182. <https://doi.org/10.1080/15481603.2018.1426092>.
- Choi Y. 2023. GeoAI: Integration of Artificial Intelligence, Machine Learning, and Deep Learning with GIS. *Applied Sciences*, 13(6): 3895. <https://doi.org/10.3390/app13063895>.
- Ekeanyanwu C.V., Obisakin I.F., Aduwenye P., Dede-Bamfo N. 2022. Merging GIS and Machine Learning Techniques: A Paper Review. *Journal of Geoscience and Environment Protection*, 10(9): 61–83. <https://doi.org/10.4236/gep.2022.109004>.
- Ezzahouani B., Teodoro A., Kharki O.El., Jianhua L., Kotaridis I., Yuan X., Ma L. 2023. Remote Sensing Imagery Segmentation in Object-Based Analysis: A Review of Methods, Optimization, and Quality Evaluation Over the Past 20 years. *Remote Sensing Applications: Society and Environment*, 32: 101031. <https://doi.org/10.1016/j.rsase.2023.101031>.
- Hossain M.D., Chen D. 2019. Segmentation for Object-Based Image Analysis (OBIA): A Review of Algorithms and Challenges from Remote Sensing Perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150: 115–134 p. <https://doi.org/10.1016/j.isprsjprs.2019.02.009>.
- Janga B., Asamani G.P., Sun Z., Cristea N. 2023. A Review of Practical AI for Remote Sensing in Earth Sciences. *Remote Sensing*, 15(16): 4112. <https://doi.org/10.3390/rs15164112>.
- Johnson B.A., Ma L. 2020. Image Segmentation and Object-Based Image Analysis for Environmental Monitoring: Recent Areas of Interest, Researchers' Views on the Future Priorities. *Remote Sensing*, 12(11): 1772. <https://doi.org/10.3390/rs12111772>.
- Li W., Hsu C.-Y. 2022. GeoAI for Large-Scale Image Analysis and Machine Vision: Recent Progress of Artificial Intelligence in Geography. *ISPRS International Journal of Geo-Information*, 11(7): 385. <https://doi.org/10.3390/ijgi11070385>.
- Mehmood M., Shahzad A., Zafar B., Shabbir A., Ali N. 2022. Remote Sensing Image Classification: A Comprehensive Review and Applications. *Mathematical Problems in Engineering*, 1: 5880959. <https://doi.org/10.1155/2022/5880959>.
- Nalluri M., Pentela M., Eluri N.R. 2020. A Scalable Tree Boosting System: XG Boost. *International Journal of Research Studies in Science, Engineering and Technology*, 7(12): 36–51. <https://doi.org/10.22259/2349-476X.0712005>.

- Radočaj D., Jurišić M. 2022. GIS-Based Cropland Suitability Prediction Using Machine Learning: A Novel Approach to Sustainable Agricultural Production. *Agronomy*, 12(9): 2210. <https://doi.org/10.3390/agronomy12092210>.
- Sagan V., Coral R., Bhadra S., Alifu H., Al Akkad O., Giri A., Esposito F. 2024. Hyperfidelis: A Software Toolkit to Empower Precision Agriculture with GeoAI. *Remote Sensing*, 16(9): 1584. <https://doi.org/10.3390/rs16091584>.
- Vali A., Comai S., Matteucci M. 2020. Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sensing*, 12(15): 2495. <https://doi.org/10.3390/rs12152495>
- Zhang Y., Liu J., Shen W. 2022. A Review of Ensemble Learning Algorithms Used in Remote Sensing Applications. *Applied Sciences*, 12(17): 8654. <https://doi.org/10.3390/app12178654>.
- Zapf A., Castell S., Morawietz L., Karch A. 2016. Measuring Inter-Rater Reliability for Nominal Data – which Coefficients and Confidence Intervals are Appropriate? *BMC Medical Research Methodology*, 16: 1–10. <https://doi.org/10.1186/s12874-016-0200-9>.

## References

- Asmus V.V., Buchnev A.A., Krovotyntsev V.A., Pyatkin V.P., Salov G.I. 2018. Planetamonitoring Software Complex in Applied Remote Sensing Problems. *Optoelectronics, Instrumentation and Data Processing*, 54(3): 222–229 (in Russian). <https://doi.org/10.3103/S8756699018030020>
- Garafutdinova L.V., Kalichkin V.K., Fedorov D.S. 2024. Object-Oriented Classification of Remote Sensing Earth Images Using Machine. *Bulletin of NSAU (Novosibirsk State Agrarian University)*, 2: 37–47 (in Russian). <https://doi.org/10.31677/2072-6724-2024-71-2-37-47>.
- Kolesnikov A.A. 2022. Analysis of Methods and Tools of Artificial Intelligence for Analysis and Interpretation of Active Remote Sensing Data. *Bulletin of SSUGiT (Siberian State University of Geosystems and Technologies)*, 27(3): 74–94 (in Russian). <https://doi.org/10.33764/2411-1759-2022-27-3-74-94>.
- Fomina E.S. 2023. Evaluation of the Efficiency of Using Specialized Neural Networks to Increase the Resolution of Images Obtained by Remote Sensing of the Earth. *Control, Communications and Security Systems*, 3: 71–90 (in Russian). <https://doi.org/10.24412/2410-9916-2023-3-71-90>.
- Yakushev V.P., Zakharyan Yu.G., Blokhina S.Yu. 2022. Current Problems and Prospects for the Use of Remote Sensing of the Earth in Agriculture. *Current Problems in Remote Sensing of the Earth from Space*, 19(1): 287–294 (in Russian). <https://doi.org/10.21046/2070-7401-2022-19-1-287-294>.
- Alom M.Z., Taha T.M., Yakopcic Ch., Westberg S., Sidike P., Nasrin M.S., Hasan M., Van Essen B.C., Awwal A.A.S., Asari V.K. 2019. A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics*, 8(3): 292. <https://doi.org/10.3390/electronics8030292>.
- Adugna T., Xu W., Fan J. 2022. Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote Sensing*, 14(3): 574. <https://doi.org/10.3390/rs14030574>.
- Basheer S., Wang X., Farooque A.A., Nawaz R.A., Liu K., Adekanmbi T., Liu S. 2022. Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing*, 14(19): 4978. <https://doi.org/10.3390/rs14194978>.
- Breiman L. 2001. Random Forests. *Machine Learning*, 45: 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Carabantes M. 2020. Black-Box Artificial Intelligence: an Epistemological and Critical Analysis. *AI & Society*, 35: 309–317. <https://doi.org/10.1007/s00146-019-00888-w>.
- Chen T., Guestrin C. 2016. Xgboost: A Scalable Tree Boosting System. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>.
- Chen G., Weng Q., Hay G.J., He Y. 2018. Geographic Object-Based Image Analysis (GEOBIA): Emerging Trends and Future Opportunities. *GIScience & Remote Sensing*, 55(2): 159–182. <https://doi.org/10.1080/15481603.2018.1426092>.
- Choi Y. 2023. GeoAI: Integration of Artificial Intelligence, Machine Learning, and Deep Learning with GIS. *Applied Sciences*, 13(6): 3895. <https://doi.org/10.3390/app13063895>.



- Ekeanyanwu C.V., Obisakin I.F., Aduwenye P., Dede-Bamfo N. 2022. Merging GIS and Machine Learning Techniques: A Paper Review. *Journal of Geoscience and Environment Protection*, 10(9): 61–83. <https://doi.org/10.4236/gep.2022.109004>.
- Ezzahouani B., Teodoro A., Kharki O.El., Jianhua L., Kotaridis I., Yuan X., Ma L. 2023. Remote Sensing Imagery Segmentation in Object-Based Analysis: A Review of Methods, Optimization, and Quality Evaluation Over the Past 20 years. *Remote Sensing Applications: Society and Environment*, 32: 101031. <https://doi.org/10.1016/j.rsase.2023.101031>.
- Hossain M.D., Chen D. 2019. Segmentation for Object-Based Image Analysis (OBIA): A Review of Algorithms and Challenges from Remote Sensing Perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150: 115–134 p. <https://doi.org/10.1016/j.isprsjprs.2019.02.009>.
- Janga B., Asamani G.P., Sun Z., Cristea N. 2023. A Review of Practical AI for Remote Sensing in Earth Sciences. *Remote Sensing*, 15(16): 4112. <https://doi.org/10.3390/rs15164112>.
- Johnson B.A., Ma L. 2020. Image Segmentation and Object-Based Image Analysis for Environmental Monitoring: Recent Areas of Interest, Researchers' Views on the Future Priorities. *Remote Sensing*, 12(11): 1772. <https://doi.org/10.3390/rs12111772>.
- Li W., Hsu C.-Y. 2022. GeoAI for Large-Scale Image Analysis and Machine Vision: Recent Progress of Artificial Intelligence in Geography. *ISPRS International Journal of Geo-Information*, 11(7): 385. <https://doi.org/10.3390/ijgi11070385>.
- Mehmood M., Shahzad A., Zafar B., Shabbir A., Ali N. 2022. Remote Sensing Image Classification: A Comprehensive Review and Applications. *Mathematical Problems in Engineering*, 1: 5880959. <https://doi.org/10.1155/2022/5880959>.
- Nalluri M., Pentela M., Eluri N.R. 2020. A Scalable Tree Boosting System: XG Boost. *International Journal of Research Studies in Science, Engineering and Technology*, 7(12): 36–51. <https://doi.org/10.22259/2349-476X.0712005>.
- Radočaj D., Jurišić M. 2022. GIS-Based Cropland Suitability Prediction Using Machine Learning: A Novel Approach to Sustainable Agricultural Production. *Agronomy*, 12(9): 2210. <https://doi.org/10.3390/agronomy12092210>.
- Sagan V., Coral R., Bhadra S., Alifu H., Al Akkad O., Giri A., Esposito F. 2024. Hyperfidelis: A Software Toolkit to Empower Precision Agriculture with GeoAI. *Remote Sensing*, 16(9): 1584. <https://doi.org/10.3390/rs16091584>.
- Vali A., Comai S., Matteucci M. 2020. Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sensing*, 12(15): 2495. <https://doi.org/10.3390/rs12152495>.
- Zhang Y., Liu J., Shen W. 2022. A Review of Ensemble Learning Algorithms Used in Remote Sensing Applications. *Applied Sciences*, 12(17): 8654. <https://doi.org/10.3390/app12178654>.
- Zapf A., Castell S., Morawietz L., Karch A. 2016. Measuring Inter-Rater Reliability for Nominal Data – which Coefficients and Confidence Intervals are Appropriate? *BMC Medical Research Methodology*, 16: 1–10. <https://doi.org/10.1186/s12874-016-0200-9>.

*Поступила в редакцию 18.09.2024;*

*поступила после рецензирования 29.10.2024;*

*принята к публикации 20.11.2024*

*Received September 18, 2024;*

*Revised October 29, 2024;*

*Accepted November 20, 2024*

**Конфликт интересов:** о потенциальном конфликте интересов не сообщалось.

**Conflict of interest:** no potential conflict of interest related to this article was reported.

## ИНФОРМАЦИЯ ОБ АВТОРАХ

**Каличкин Владимир Климентьевич**, доктор сельскохозяйственных наук, профессор, главный научный сотрудник, Сибирский федеральный научный центр агробиотехнологий Российской академии наук, руководитель направления Земледелие, Новосибирская область, р.п. Краснообск, Россия

## INFORMATION ABOUT THE AUTHORS

**Vladimir K. Kalichkin**, Doctor of Agricultural Sciences, Professor, Chief Scientific Officer, Siberian Federal Scientific Centre of AgroBioTechnologies of the Russian Academy of Sciences, Head of the Agriculture department, Novosibirsk region, Krasnoobsk working settlement, Russia



**Гарафутдинова Людмила Вячеславовна**, аспирант, младший научный сотрудник, Сибирский федеральный научный центр агробиотехнологий Российской академии наук, лаборатория агроклиматических исследований, Новосибирская область, р.п. Краснообск, Россия

**Федоров Дмитрий Сергеевич**, младший научный сотрудник, Сибирский федеральный научный центр агробиотехнологий Российской академии наук, лаборатория агроклиматических исследований, Новосибирская область, р.п. Краснообск, Россия

**Lyudmila V. Garafutdinova**, Graduate Student, Junior Researcher, Siberian Federal Scientific Centre of AgroBioTechnologies of the Russian Academy of Sciences, Laboratory of Agroclimatic Research, Novosibirsk region, Krasnoobsk working settlement, Russia

**Dmitry S. Fedorov**, Junior Researcher, Siberian Federal Scientific Centre of AgroBioTechnologies of the Russian Academy of Sciences, Laboratory of Agroclimatic Research, Novosibirsk region, Krasnoobsk working settlement, Russia