

ОБЪЕКТНО ОРИЕНТИРОВАННАЯ КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

Л.В. Гарафутдинова, аспирант

В.К. Каличкин, доктор сельскохозяйственных наук, профессор

Д.С. Федоров, инженер-программист

Сибирский федеральный научный центр агробиотехнологий Российской академии наук, Новосибирск, Россия

E-mail: lv.garafutdinova@mail.ru

Ключевые слова: дистанционное зондирование, сегментация, классификация, машинное обучение, ГИС.

Реферат. Приведены результаты исследований по разработке автоматизированной классификации снимков дистанционного зондирования Земли внутрихозяйственного землепользования на основе применения объектно ориентированного подхода, машинного обучения и геоинформационного моделирования. Методология классификации включала три этапа: анализ цифровых изображений с выделением пространственных объектов путем предварительной сегментации, классификация пространственных объектов с использованием алгоритмов машинного обучения (RF и SVM), оценка общей точности полученного результата. Для обработки использовали космические снимки Sentinel-2 с мая по апрель на территорию землепользования ОС «Элитная» и ИП ГК(Ф)Х Ковалев С.М. Новосибирской области с пространственным разрешением 10 м в пикселе. Обработка полученных мультиспектральных снимков проходила с применением программного продукта SAGA GIS версии 8.5.1 и QGIS с открытым исходным кодом, создание моделей классификации осуществляли в пакете статистического языка программирования R. Установлено, что общая точность классификации объектов землепользования, отображенных на космических снимках, для территории ОС «Элитная» алгоритмом SVM составила 87,1 % (коэффициент Каппа 0,74), алгоритмом RF – 90,3 % (коэффициент Каппа 0,87). Для территории землепользования ИП ГК(Ф)Х Ковалев С.М. – алгоритмом SVM – 78,4 % (коэффициент Каппа 0,78), алгоритмом RF – 82,3 % (коэффициент Каппа 0,82). Объектно ориентированный подход в интеграции с машинным обучением способствует эффективной сегментации и классификации снимков дистанционного зондирования для выделения пространственных объектов, дает возможность автоматизировать процесс картографирования территории землепользования и включать эту информацию в геоинформационное моделирование оценки и классификации земель сельскохозяйственного назначения.

OBJECT-ORIENTED CLASSIFICATION OF REMOTE SENSING EARTH IMAGES USING MACHINE

L.V. Garafutdinova, graduate student

V.K. Kalichkin, Doctor of Agricultural Sciences, Professor

D.S. Fedorov, software engineer

Siberian Federal Scientific Center for Agrobiotechnologies of the Russian Academy of Sciences, Novosibirsk, Russia

E-mail: lv.garafutdinova@mail.ru

Keywords: remote sensing, segmentation, classification, machine learning, GIS.

Abstract. The results of research on the development of automated classification of remote sensing images of the Earth for on-farm land use based on the use of an object-oriented approach, machine learning and geoinformation modeling are presented. The classification methodology included three stages: analysis of digital images with the selection of spatial objects through preliminary segmentation, classification of spatial objects using the Random Forest (RF) and Support Vector Machine (SVM) machine learning algorithms, and assessment of the overall accuracy of the result. For processing, satellite images Sentinel-2 from May to April for the land use area of the experimental station «Elitnaya» and Individual Enterprise of State Farm (Collective Farm) Kovalev S.M. of the Novosibirsk region with a spatial resolution of 10 m per pixel were used. The processing of the resulting multispectral images was carried out using the software product SAGA GIS version 8.5.1 and QGIS with open-source code, the creation of classification models was carried out in the package of the statistical programming

language R. It was established that the overall accuracy of classification of land use objects displayed on satellite images, for the territory of the experimental station «Elitnaya» the SVM algorithm was 87.1% (kappa coefficient 0.74), and using the RF algorithm – 90.3% (kappa coefficient 0.87). For the land use area of the Individual Enterprise of State Farm (Collective Farm) Kovalev S.M. using the SVM algorithm – 78.4% (kappa coefficient 0.78), and using the RF algorithm – 82.3% (kappa coefficient 0.82). The object-oriented approach, in integration with machine learning, facilitates efficient segmentation and classification of remote sensing images for the delineation of spatial objects, provides the ability to automate the mapping process of land use areas, and to incorporate this information into geoinformation modeling for evaluation and classification of agricultural lands.

Классификация многозональных космических снимков дистанционного зондирования Земли (ДЗЗ) представляет собой многоуровневый процесс, при котором каждый пиксель или область изображения объединяются по определенным правилам в объекты (классы) на основе их спектральных и структурных характеристик. Целью классификации изображений ДЗЗ является преобразование спутниковых снимков в полезную информацию. Она осуществляется с помощью множества различных подходов и методов, которые могут применяться в соответствии с конкретными условиями и задачами. Эти подходы и методы подразделяются на пять категорий: контролируемая классификация, неконтролируемая классификация, классификация на основе пикселей, объектно ориентированная классификация и классификация сверточных нейронных сетей (CNN) [1–4].

Процесс классификации довольно трудоемкий и требует значительных усилий. Поэтому в последние годы для ускорения и повышения точности процессов сегментации и классификации снимков ДЗЗ осуществляется поиск приемлемых алгоритмов машинного обучения. Для этих целей используются машины опорных векторов (Support Vector Machines – SVM) [5, 6], случайный лес (Random Forest – RF) [7, 8], сверточные нейронные сети (Convolutional Neural Networks – CNN) [9, 10] и др. Например, в исследовании [11] по идентификации изменений в землепользовании и растительном покрове оценивались SVM, K-ближайших соседей (K-Nearest Neighbours – KNN), RF, квантование обучающих векторов (Learning Vector Quantization – LVQ), рекурсивное разбиение, деревья регрессии (Recursive Partitioning, Regression Trees – RPART) и стохастическое усиление градиента (Stochastic Gradient Boosting – GBM). Результаты продемонстрировали, что SVM достиг более высокой общей точности и коэффициентов Каппа, чем второй лучший

классификатор RF. Оба классификатора превосходили по точности другие алгоритмы.

Объектно ориентированная классификация в интеграции с ГИС (GEOBIA) благодаря улучшениям в алгоритмах сегментации изображений, а также применению машинного обучения становится все более популярной по сравнению с традиционным пиксельным анализом [12, 13]. GEOBIA позволяет объединять спектральные данные с тематическими картами и знаниями экспертов для дополнения процесса классификации изображений с целью повышения уровня доверия к результатам дешифрирования [14, 15].

Оценка точности является фундаментальным шагом в обработке изображений ДЗЗ. Методы оценки направлены на вычисление точности классификации и характеристики ошибок. Общая точность классификации обычно определяется геометрическим соответствием между объектами земной поверхности и классами (объектами) изображения или путем измерения степени чрезмерной и недостаточной сегментации целевых эталонных единиц [16, 17].

Целью исследований является поиск приемлемого алгоритма машинного обучения в интеграции с объектно ориентированным подходом для автоматизированной классификации изображений ДЗЗ внутрихозяйственного землепользования.

ОБЪЕКТЫ И МЕТОДЫ ИССЛЕДОВАНИЙ

Исследования выполнены на территории землепользования ОС «Элитная» (54°54'57" с.ш., 82°57'6" в.д.) Новосибирского района и ИП ГК(Ф)Х Ковалев С.М. (54°22'37.64" с.ш., 82°47'18.73" в.д.) Искитимского района Новосибирской области, расположенных в центральной лесостепной подзоне. Рельеф ОС «Элитная» представлен слабоволнистой

равниной с абсолютными высотами от 103 до 170 м. В почвенном покрове преобладают чернозем выщелоченный и темно-серая лесная почва. Территория ИП ГК(Ф)Х Ковалев С.М. 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 почвы, чернозем выщелоченный и луговые почвы.

Для распознавания и классификации объектов внутрихозяйственного землепользования использованы многозональные космические снимки Sentinel-2 с пространственным разрешением 10 м в пикселе за апрель – начало мая, полученные при помощи Sentinelhub (<https://www.sentinel-hub.com>). Из 13 спектральных каналов Sentinel-2 в работе использовали три полосы видимого диапазона (RGB) – красный (B02), зеленый (B03) и синий (B04). Для повышения точности сегментации и классификации пространственных объектов, имеющих на территории землепользования, выбраны снимки с отсутствием на них растительности.

Рабочий процесс объектно ориентированной классификации состоял из выполнения следующих этапов: сегментация (получение объектов изображения) многозональных космических снимков Sentinel-2 с использованием OBIS; классификация полученного сегментированного изображения с использованием алгоритмов машинного обучения; оценка точности полученных результатов посредством построения матрицы неточностей и расчетов коэффициента Каппа.

С помощью программного продукта SAGA GIS версии 8.5.1 с открытым исходным кодом были проведены геометрические, радиометрические преобразования и анализ полученного интегрированного снимка на основе объектов для реализации эффективной сегментации, которую проводили с использованием алгоритма Object Based Image Segmentation (OBIS). Алгоритм OBIS в SAGA GIS позволяет объединить несколько модулей в один процесс автоматизированной сегментации изображений. Теоретическая основа алгоритма сегментации OBIA/OBIS описана в работах [18, 19].

Формирование обучающей выборки для классификации выполняли посредством экс-

пертного анализа пространственных объектов. Классификацию полученных объектов осуществляли с использованием алгоритмов машинного обучения – SVM и RF в пакете статистического языка программирования R. Оценку точности полученных результатов проводили с помощью матрицы путаницы и коэффициента Каппа Коэна. Последующее отображение полученных результатов в виде карт 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 ИССЛЕДОВАНИЙ И ИХ ОБСУЖДЕНИЕ

В последнее время GEOBIA все чаще применяется для классификации ДЗЗ. В GEOBIA изображения сначала сегментируются на объекты, которые представляют собой группы пикселей (участки земли), которые впоследствии могут быть классифицированы по представляющим интерес категориям с помощью алгоритмов машинного обучения. Ключевые преимущества GEOBIA по сравнению с методами, основанными на пикселях, включают: 1) возможность учитывать при классификации, в дополнение к спектральным значениям слоев входного изображения, форму, текстуру на уровне объекта и контекстуальные переменные; 2) сглаживание некоторых локальных вариаций внутри объектов, что может уменьшить шум («соль с перцем») и повысить точность классификации и 3) учет территориальной иерархии участков и тип покрытия, путем работы с несколькими слоями объектов, вложенных друг в друга в разных пространственных масштабах. Аппроксимация наземных объектов и участков объектами изображения делает их более значимыми и потенциально более устойчивыми к незначительным ошибкам геопространственного позиционирования и регистрации изображений, чем пиксельные единицы.

Одним из основных этапов обработки изображений ДЗЗ является сегментация, которая осуществляется с целью разделения изображения на сегменты, содержащие однотипные по своим визуальным характеристикам пиксели. Каждому пикселю присваивается опре-

деленная метка (номер сегмента) с последующим формированием сегментов карты. Такая обработка позволяет выделить на изображении однородные территории (поле, водоем, дороги, строения и др.), последующий анализ которых существенно проще по сравнению с фоновыми исследованиями неоднородных космических снимков. Сегментация многозональных космических изображений заключается также в разделении всей области исходного изображения на полигональные объекты с определенными схожими характеристиками, включая спектр, текстуру и форму [20].

Для решения задачи классификации пространственных объектов важно не только выделить класс поверхности, но и определить его границы. Для этих целей применялся алгоритм OBIS. При использовании данного алгоритма группировка пикселей в сегменты (объекты) происходила посредством итеративного процесса. Значение ширины полосы пропускания для генерации, используемое в методе OBIS, выбиралось экспертным способом в соответствии с размером исследуемой области и пространственным разрешением космического снимка. В нашем случае ширина полосы пропускания (размер) для генерации начального числа была выбрана равной десяти.

После того, как пространственное разрешение изображения дистанционного зонди-

рования определено, значение размера должно быть соответствующим образом уменьшено для исследуемой территории с меньшими пространственными участками и более рассредоточенным их распределением. Для исследуемой области с более крупными участками и более концентрированным пространственным распределением значение размера должно быть увеличено [21]. Таким образом, для нахождения оптимального варианта для более точного отображения объектов на снимке были использованы различные значения ширины полосы пропускания. При этом было установлено, что чем выше ее значение, тем больше других сегментов включается в полученные классы объектов. Если сформировать объекты с пороговым значением меньше трех, то в них входят в основном шумы. Поэтому было принято решение оставить ширину полосы пропускания для генерации классов объектов равной десяти.

В результате сегментации на основании анализа отражательной способности объектов многозонального космического изображения территории ОС «Элитная» размером 439×270 пикселей был сформирован 4 641 сегмент (рис. 1, а). На изображении территории ИП ГК(Ф)Х Ковалев размером $1\,632 \times 1\,188$ пикселей было сформировано 6 864 сегмента (рис. 1, б).




Рис. 1. Сегментация территории ОС «Элитная» (а) и ИП ГК(Ф)Х Ковалев С.М. (б)

Fig. 1. Segmentation of the territory of the ES «Elitnaya» (a) and the individual entrepreneur State Farm (Collective Farm) Kovalev S.M. (b)

Следует отметить, что при сегментации объектов недвижимости наблюдалась путани-

ца с другими пространственными объектами, которая скорее всего происходила из-за счет

недостаточного пространственного разрешения (10 м в пикселе) и близких спектральных характеристик различных объектов. Кроме того, пиксели (т.е. элементы изображения) представляют собой отдельные наблюдения земной поверхности в определенном месте с относительными или абсолютными кортежами координат реального мира. Они не несут никаких пространственных свойств в дополнение к их относительному или абсолютному местоположению, яркости или значению цвета. И наоборот, человеческое зрение ведет себя диаметрально иначе: человек может интерпретировать и понимать изображения только тогда, когда отдельные пиксели игнорируются и пространственно объединяются в воспринимаемые значимые целые [14]. Например, при визуальной интерпретации панхроматических и цветных изображений ДЗЗ сельскохозяйственные поля обычно обнаруживаются на основе свойств формы и размера, в то время как определение конкретного типа культуры может зависеть от цвета.

Современные технологии использования космических снимков предусматривают цифровую обработку данных. Применяются два основных вида дешифрирования – визуальное (экспертное) и автоматизированное (машинное). Последнее включает задачи классификации изображений на основе процесса самообучения алгоритмов распознавания. Обучение классификаторов проводилось на основе знаний эксперта и полученных сегментов (объектов). Протестировано два алгоритма машинного обучения: RF и SVM.

RF является ансамблевым классификатором решающих деревьев для принятия решения о классовой принадлежности объекта. Случайные леса представляют собой комбинацию предикторов деревьев таким образом, что каждое дерево зависит от значений случайного вектора, отобранного независимо и с одинаковым распределением для всех деревьев в лесу [22]. Достижение высокого качества классификации данным алгоритмом происходит за счет объединения «слабых» деревьев, при этом допускается, что любое одно дерево не является

оптимальным. Данные, не используемые при обучении, известны как исходные данные (out-of-bag – OOB) и могут применяться для независимой оценки общей точности классификации [1]. Для настройки модели RF был выбран оптимальный параметр – количество деревьев в каждой итерации, равной 10 шт., основанной на результатах оценки OOB, а затем проведено обучение с оптимальным числом деревьев.

SVM – это непараметрический алгоритм, основанный на теории статистического обучения [23]. SVM фокусируется исключительно на обучающих выборках, которые в пространстве признаков наиболее близки к оптимальной границе между классами, является двоичным и определяет единую границу между двумя классами [24, 25]. В наших исследованиях это ограничение было устранено путем проекции пространства признаков на более высокое измерение с предположением, что линейная граница может существовать в этом пространстве. Представленная проекция на более высокую размерность известна как «трюк с ядром». При обучении модели SVM в качестве ядра была использована радиальная базисная функция (RBF).

На основе экспертной оценки изображения ДЗЗ территории землепользования ОС «Элитная» было сформировано 5 классов пространственных объектов, каждый класс содержал не менее 20 сегментов изображения.

Для классификации пространственных объектов с помощью алгоритмов машинного обучения данные со значениями классов объектов были разделены на обучающую и тестовую выборки. Для подтверждения согласованности каждого пространственного объекта в обучающем и проверочном наборах данных использовался метод стратифицированной выборки.

Для территории ОС «Элитная» использовалась обучающая выборка, состоящая из 103 объектов пространственной выборки, а для оценки точности модели (тестовая выборка) – из 31 объекта пространственной выборки. Результаты машинного обучения представлены на тематических картах (рис. 2).




Рис. 2. Классификация многозональных космических снимков ОС «Элитная» с помощью алгоритмов RF (а) и SVM (б)

Fig. 2. Classification of multispectral satellite images from ES «Elitnaya» using RF (a) and SVM (b) algorithms

Для территории землепользования ИП ГК(Ф)Х Ковалев С.М. были сформированы 7 классов пространственных объектов, обучающая выборка состояла из 184 объектов про-

странственной выборки, а тестовая выборка – из 79 объектов пространственной выборки. Результаты машинного обучения представлены на тематических картах (рис. 3).




Рис. 3. Классификация многозональных космических снимков ИП ГК(Ф)Х Ковалев С.М. с помощью алгоритмов RF (а) и SVM (б)

Fig. 3. Classification of multispectral satellite images State Farm (Collective Farm) Kovalev S.M. using RF (a) and SVM (b) algorithms

При классификации изображений ДЗЗ на территорию землепользования ИП ГК(Ф)Х Ковалев С.М. на начальном этапе анализа снимка для каждого сформированного класса

пространственных объектов обучающая выборка содержала около 20 сегментов. После проведения классификации было установлено, что точность полученного результата составила

в среднем около 60 %. После анализа полученного результата, а также учета того, что площадь данного землепользования превышает площадь ОС «Элитная» в 3,7 раза, было принято решение увеличить объем выборки входящих в класс объектов до 40 сегментов. В результате оказался сформирован набор эталонных сегментов, каждый из которых составлял в среднем 3,8 % от общей площади классификации.

Для оценки общей точности результатов классификации изображений ДЗЗ с использованием алгоритмов RF и SVM были созданы матрицы путаницы (табл. 1, 2).

Матрица путаницы – это табличное представление для описания производительности

модели классификации на наборе тестовых данных, для которых известны фактические значения. Создание матрицы позволяет легко идентифицировать путаницу между классами, т.е. когда один класс ошибочно помечен как другой [26]. Вертикальные столбцы в таблице матрицы путаницы отражают фактические классы, а горизонтальные – предсказанные классы. Диагональ представляет собой число правильно классифицированных классов объектов. Значения вне диагонали показывают ошибки классификации между соответствующими классами.

Таблица 1

Матрицы путаницы классификации мультиспектрального изображения на территорию ОС «Элитная»
Confusion matrices for classifying a multispectral image into the territory of the ES «Elitnaya»

RF					
Объект	1	2	3	4	5
1	5	0	0	0	0
2	2	1	1	0	0
3	0	0	7	0	0
4	0	0	0	7	0
5	0	0	0	0	8

SVM					
Объект	1	2	3	4	5
1	5	0	0	0	0
2	0	0	1	1	2
3	0	0	7	0	0
4	0	0	0	7	0
5	0	0	0	0	8

Примечание. С 1 по 3 – пространственные объекты; 4 – асфальтированная поверхность; 5 – объекты недвижимости.

Расчет результатов оценки точности выполнен по формуле:

$$\text{Accuracy assessments} = (T/N) \times 100,$$

где T – количество правильно классифицированных объектов; N – общее количество объектов выборки.

В результате расчета показателя общей точности (Accuracy assessments) классификации пространственных объектов землепользования, отображенных на космических снимках, для территории ОС «Элитная» алгоритмом RF составила 90,32 %, алгоритмом SVM – 87,10 %. Следует отметить, что при классификации «второй пространственный объект» алгоритмом SVM не был классифицирован, а в других случаях он путался с «третьим пространственным объектом», «асфальтированной поверхностью» и «объектами недвижимости». Объясняется это скорее всего тем, что иногда происходит

внутрипиксельное смешивание спектральных характеристик объектов, и алгоритм SVM не всегда справляется с этим эффектом.

Для территории землепользования ИП ГК(Ф)Х Ковалев С.М. алгоритмом RF общая точность полученного результата составила 82,27 %, а алгоритмом SVM – 78,40 % (табл. 2). В данном объекте классификации алгоритмом SVM «пятый пространственный объект» классифицирован как «третий пространственный объект» и «объекты недвижимости». «Объекты недвижимости» обоими методами были неверно классифицированы, а также «четвертый пространственный объект». Ошибки при проведении сегментации оказывают влияние на дальнейшее проведение классификации вследствие объединения в пространственный объект неправильно отнесенных пикселей.

**Матрицы путаницы классификации многозонального изображения на территорию
ИП ГК(Ф)Х Ковалев С.М.
Confusion matrices for the classification of a multispectral image into the territory
of State Farm (Collective Farm) Kovalev S.M.**

	RF						
Объект	1	2	3	4	5	6	7
1	15	1	0	0	0	0	1
2	0	19	0	0	0	0	0
3	0	0	7	0	0	5	0
4	0	0	0	4	1	0	0
5	0	0	0	0	8	2	0
6	0	0	2	0	2	8	0
7	0	0	0	0	0	0	4

	SVM						
Объект	1	2	3	4	5	6	7
1	17	0	0	0	0	0	0
2	0	19	0	0	0	0	0
3	0	1	6	0	0	5	0
4	0	0	0	4	1	0	0
5	0	0	1	0	4	5	0
6	0	0	2	0	2	8	0
7	0	0	0	0	0	0	4

Примечание. С 1 по 5 – пространственные объекты; 6 – объекты недвижимости; 7 – водные объекты.

Применение алгоритмов SVM и RF показали удовлетворительные результаты классификации. Исходя из результатов, представленных в матрице неточностей, отчетливо прослеживается, что большинство объектов были классифицированы правильно.

Кроме того, рассматривались другие показатели, полученные из матрицы ошибок. В частности, использовалась статистика Каппа по формулам, приведенным в [27]. Статистика Каппа измеряет согласованность между истинной категорией пространственных объектов и предсказанной моделью. Чем выше Каппа, тем выше точность классификации. Коэффициент Каппа, по существу, оценивает эффективность общей классификации.

Проведенный расчет показал, что для территории ОС «Элитная» общая точность классификации изображения ДЗЗ алгоритмом RF коэффициент Каппа равна 0,87, алгоритмом SVM – 0,74. Для территории землепользования ИП ГК(Ф)Х Ковалев С.М. алгоритмом RF коэффициент Каппа составляет 0,82, алгоритмом SVM – 0,78.

В целом протестированные алгоритмы машинного обучения RF и SVM показали достаточно высокую общую точность классификации пространственных объектов. В результате проведенного анализа в основном была решена проблема шума («соль с перцем»), а информация о границах пространственных объек-

тов учтена более полно, чем при пиксельном подходе.

ВЫВОДЫ

1. Объектно ориентированный подход, состоящий из трех этапов, – сегментации, классификации и проверки точности с использованием машинного обучения – является более перспективным методом в сравнении с пиксельным анализом, облегчает процесс распознавания и классификации пространственных объектов и может использоваться непосредственно в геоинформационном моделировании оценки и типизации земель сельскохозяйственного назначения.

2. Для повышения общей точности классификации многозональных космических снимков целесообразно использовать алгоритм RF, который для обоих изученных объектов землепользования показал лучшие результаты (точность 82,27–90,32 %, коэффициент Каппа 0,82–0,87) по сравнению с алгоритмом SVM (точность 78,40–87,10 %, коэффициент Каппа 0,74–0,78).

3. При классификации изображений ДЗЗ с повышенным разнообразием природных объектов и спектральных характеристик в разных сценах для увеличения общей точности классификации целесообразно увеличить количество сегментов при выделении пространственного объекта примерно в 2 раза.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Maxwell A.E., Warner T.A., Fang F. Implementation of machine-learning classification in remote sensing: An applied review // *International journal of remote sensing*. – 2018. – Vol. 39, N 9. – P. 2784–2817. – DOI: 10.1080/01431161.2018.1433343.
2. Dhingra S., Kumar D. A review of remotely sensed satellite image classification // *International Journal of Electrical and Computer Engineering*. – 2019. – Vol. 9, N 3. – P. 1720–1731. – DOI: 10.11591/ijece.v9i3.pp.1720-1731.
3. Ouchra H., Belangour A. Satellite image classification methods and techniques: A survey // 2021 IEEE International Conference on Imaging Systems and Techniques (IST). – IEEE, 2021. – P. 1–6. – DOI: 10.1109/IST50367.2021.9651454.
4. Remote sensing image classification: A comprehensive review and applications / M. Mehmood, A. Shahzad, B. Zafar, A. Shabbir // *Mathematical Problems in Engineering*. – 2022. – Vol. 2022. – P. 1–24. – DOI: 10.1155/2022/5880959.
5. Mountrakis G., Im J., Ogole C. Support vector machines in remote sensing: A review // *ISPRS journal of photogrammetry and remote sensing*. – 2011. – Vol. 66, N 3. – P. 247–259. – DOI: 10.1016/j.isprsjprs.2010.11.001.
6. Белов А.М., Денисова А.Ю. Классификация изображений ДЗЗ с использованием алгоритма комплексирования данных различных сенсоров // *Компьютерная оптика*. – 2020. – Т. 44, № 4. – С. 627–635. – DOI: 10.18287/2412-6179-CO-735.
7. Akar Ö., Güngör O. Classification of multispectral images using Random Forest algorithm // *Journal of Geodesy and Geoinformation*. – 2012. – Vol. 1, N 2. – P. 105–112. – DOI: 10.9733/jgg.241212.1.
8. Колесников А.А. Анализ методов и средств искусственного интеллекта для анализа и интерпретации данных активного дистанционного зондирования // *Вестник СГУГИТ*. – 2022. – Т. 27, № 3. – С. 74–94.
9. Семантическая сегментация данных дистанционного зондирования Земли при помощи нейросетевых алгоритмов / А.А. Друки, В.Г. Спицин, Ю.А. Болотова, А.А. Башлыков // *Известия Томского политехнического университета. Инжиниринг георесурсов*. – 2018. – Т. 329, № 1. – С. 59–68.
10. A survey of remote sensing image classification based on CNNs / J. Song, S. Gao, Y. Zhu, Ch. Ma // *Big earth data*. – 2019. – Vol. 3, N 3. – P. 232–254. – DOI: 10.1080/20964471.2019.1657720.
11. Comparing supervised algorithms in Land Use and Land Cover classification of a Landsat time-series / T. Nery, R. Sadler, M. Solis-Aulestiaet, B. White // 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing, China, 2016. – P. 5165–5168. – DOI: 10.1109/IGARSS.2016.7730346.
12. Geographic object-based image analysis-towards a new paradigm / T. Blaschke, G.J. Hay, M. Kelly, S. Lang // *ISPRS journal of photogrammetry and remote sensing*. – 2014. – Vol. 87. – P. 180–191. – DOI: 10.1016/j.isprsjprs.2013.09.014.
13. Geographic object-based image analysis (GEOBIA): Emerging trends and future opportunities / G. Chen, Q. Weng, G.J. Hay, Y. He // *GIScience & Remote Sensing*. – 2018. – Vol. 55, N 2. – P. 159–182. – DOI: 10.1080/15481603.2018.1426092.
14. GEOBIA Achievements and Spatial Opportunities in the Era of Big Earth Observation Data / S. Lang, G.J. Hay, A. Baraldi, D. Tiede // *ISPRS International Journal of Geo-Information*. – 2019. – Vol. 8, N 11. – P. 474. – DOI: 10.3390/ijgi8110474.
15. Object-oriented method combined with deep convolutional neural networks for land-use-type classification of remote sensing images / B. Jin, P. Ye, X. Zhang, W. Song, S. Li // *Journal of the Indian Society of Remote Sensing*. – 2019. – Vol. 47. – P. 951–965. – DOI: 10.1007/s12524-019-00945-3.
16. Accuracy assessment measures for object-based image segmentation goodness / N. Clinton, A. Holt, J. Scarborough, A. Holt, L. Yan. // *Photogrammetric Engineering & Remote Sensing*. – 2010. – Vol. 76, N 3. – P. 289–299. – DOI: 0099-1112/10/7603-0289/\$3.00/0.
17. Ye S., Pontius Jr.R.G., Rakshit R. A review of accuracy assessment for object-based image analysis: From per-pixel to per-polygon approaches // *ISPRS Journal of Photogrammetry and Remote Sensing*. – 2018. – Vol. 141. – P. 137–147. – DOI: 10.1016/j.isprsjprs.2018.04.002.
18. Labib S.M., Harris A. The potentials of Sentinel-2 and LandSat-8 data in green infrastructure extraction, using object based image analysis (OBIA) method // *European Journal of Remote Sensing*. – 2018. – Vol. 51, N 1. – P. 231–240. – DOI: 10.1080/22797254.2017.1419441.

19. Hossain M.D., Chen D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective // *ISPRS Journal of Photogrammetry and Remote Sensing*. – 2019. – Vol. 150. – P. 115–134. – DOI: 10.1016/j.isprsjprs.2019.02.009.
20. Assessing the performance of different OBIA software approaches for mapping invasive alien plants along roads with remote sensing data / P. Lourenço, A.C. Teodoro, J.A. Gonçalves, P.J. Honrado // *International Journal of Applied Earth Observation and Geoinformation*. – 2021. – Vol. 95. – P. 102263. – DOI: 10.1016/j.jag.2020.102263.
21. Lemenkova P. Object based image segmentation algorithm of SAGA GIS for detecting urban spaces in yaoundé, Cameroon // *Central European Journal of Geography and Sustainable Development*. – 2020. – Vol. 2, N 2. – P. 38–51. – DOI:10.47246/CEJGSD.2020.2.2.4.
22. Breiman L. Random forests // *Machine Learning*. – 2001. – Vol. 45. – P. 5–32. – DOI: 10.1023/A:1010933404324.
23. Cortes C., Vapnik V. Support-vector networks // *Machine Learning*. – 1995. – Vol. 20. – P. 273–297. – DOI: 10.1007/BF00994018.
24. Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review / M. Sheykhmousa, M. Mahdianpari, H. Ghanbari [et al.] // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. – 2020. – Vol. 13. – P. 6308–6325. [Электронный ресурс]. – URL: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9206124> (дата обращения: 03.09.2023).
25. Object-based wetland vegetation classification using multi-feature selection of unoccupied aerial vehicle RGB imagery / R. Zhou, C. Yang, E. Li, X. Cai // *Remote Sensing*. – 2021. – Vol. 13, N 23. – P. 4910. – DOI:10.3390/rs13234910.
26. Старовойтов В.В., Голуб Ю.И. Об оценке результатов классификации несбалансированных данных по матрице ошибок // *Информатика*. – 2021. – Т. 18, № 1. – С. 61–71. – DOI: 10.37661/1816-0301-2021-18-1-61-71.
27. Jenness J., Wynn J.J. Kappa Analysis (kappa_stats.avx) Extension for ArcView 3.x. Jenness Enterprises. 2007. [Электронный ресурс]. – URL: http://www.jennessent.com/arcview/kappa_stats.htm (дата обращения: 07.09.2023).

REFERENCES

1. Maxwell A.E., Warner T.A., Fang F., Implementation of machine-learning classification in remote sensing: An applied review, *International journal of remote sensing*, 2018, Vol. 39, No. 9, P. 2784–2817, DOI:10.1080/01431161.2018.1433343.
2. Dhingra S, Kumar D., A review of remotely sensed satellite image classification, *International Journal of Electrical and Computer Engineering*, 2019, Vol. 9, No. 3, pp. 1720–1731, DOI: 10.11591/ijece.v9i3.pp.1720-1731.
3. Ouchra H, Belangour A., Satellite image classification methods and techniques: A survey, *2021 IEEE International Conference on Imaging Systems and Techniques (IST)*. IEEE, 2021, P. 1–6, DOI: 10.1109/IST50367.2021.9651454.
4. Mehmood M., Shahzad A., Zafar B., Shabbir A., Remote sensing image classification: A comprehensive review and applications, *Mathematical Problems in Engineering*, 2022, Vol. 2022, P. 1–24, DOI: 10.1155/2022/5880959.
5. Mountrakis G., Im J., Ogole C., Support vector machines in remote sensing: A review, *ISPRS journal of photogrammetry and remote sensing*, 2011, Vol. 66, No. 3, pp. 247–259, DOI: 10.1016/j.isprsjprs.2010.11.001.
6. Belov A.M., Denisova A.U., *Komputernaya optika*, 2020, T. 44, No. 4, pp. 627–635, DOI: 10.18287/2412-6179-CO-735. (In Russ.)
7. Akar Ö., Güngör O., Classification of multispectral images using Random Forest algorithm, *Journal of Geodesy and Geoinformation*, 2012, Vol. 1, No. 2, pp. 105–112, DOI: 10.9733/jgg.241212.1.
8. Kolesnikov A.A., *Vestnik SGUGIT*, 2022, T. 27, No. 3, pp. 74–94. (In Russ.)
9. Druki A.A., Spitsin V.G., Bolotova Yu.A., Bashlykov A.A., *Izvestia Tomskogo politexnicheskogo universiteta, Inzinirovanie georesursov*, 2018, T. 329, No. 1, pp. 59–68. (In Russ.)
10. Song J., Gao S., Zhu Y., Ma Ch., A survey of remote sensing image classification based on CNNs, *Big earth data*, 2019, Vol. 3, No. 3, pp. 232–254, DOI: 10.1080/20964471.2019.1657720.

11. Nery T., Sadler R., Solis-Aulestiaet M., White B., Comparing supervised algorithms in Land Use and Land Cover classification of a Landsat time-series, *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China*, 2016, pp. 5165–5168, DOI: 10.1109/IGARSS.2016.7730346.
12. Blaschke T., Hay G.J., Kelly M., Lang S., Geographic object-based image analysis-towards a new paradigm, *ISPRS journal of photogrammetry and remote sensing*, 2014, Vol. 87, pp. 180–191, DOI: 10.1016/j.isprsjprs.2013.09.014.
13. Chen G., Weng Q., Hay G.J., He Y., Geographic object-based image analysis (GEOBIA): Emerging trends and future opportunities, *GIScience & Remote Sensing*, 2018, Vol. 55, No. 2, pp. 159–182, DOI: 10.1080/15481603.2018.1426092.
14. Lang S., Hay G.J., Baraldi A., Tiede D., GEOBIA Achievements and Spatial Opportunities in the Era of Big Earth Observation Data, *ISPRS International Journal of Geo-Information*, 2019, Vol. 8, No. 11, pp. 474, DOI: 10.3390/ijgi8110474.
15. Jin B., Ye P., Zhang X., Song W., Li S., Object-oriented method combined with deep convolutional neural networks for land-use-type classification of remote sensing images, *Journal of the Indian Society of Remote Sensing*, 2019, Vol. 47, pp. 951–965, DOI: 10.1007/s12524-019-00945-3.
16. Clinton N., Holt A., Scarborough J., Holt A., Yan L., Accuracy assessment measures for object-based image segmentation goodness, *Photogrammetric Engineering & Remote Sensing*, 2010, Vol. 76, No. 3, pp. 289–299, DOI: 0099-1112/10/7603-0289/\$3.00/0.
17. Ye S., Pontius Jr. R.G., Rakshit R., A review of accuracy assessment for object-based image analysis: From per-pixel to per-polygon approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, Vol. 141, pp. 137–147, DOI: 10.1016/j.isprsjprs.2018.04.002.
18. Labib S.M., Harris A., The potentials of Sentinel-2 and LandSat-8 data in green infrastructure extraction, using object based image analysis (OBIA) method, *European Journal of Remote Sensing*, 2018, Vol. 51, No. 1, P. 231–240, DOI: 10.1080/22797254.2017.1419441.
19. Hossain M.D., Chen D., Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective, *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, Vol. 150, pp. 115–134, DOI: 10.1016/j.isprsjprs.2019.02.009.
20. Lourenço P., Teodoro A.C., Gonçalves J.A., Honrado P.J., Assessing the performance of different OBIA software approaches for mapping invasive alien plants along roads with remote sensing data, *International Journal of Applied Earth Observation and Geoinformation*, 2021, Vol. 95, pp. 102263, DOI: 10.1016/j.jag.2020.102263.
21. Lemenkova P., Object based image segmentation algorithm of SAGA GIS for detecting urban spaces in yaoundé, Cameroon, *Central European Journal of Geography and Sustainable Development*, 2020, Vol. 2, No. 2, pp. 38–51, DOI: 10.47246/CEJGSD.2020.2.2.4.
22. Breiman L., Random forests, *Machine Learning*, 2001, Vol. 45, pp. 5–32, DOI: 10.1023/A:1010933404324.
23. Cortes C., Vapnik V., Support-vector networks, *Machine Learning*, 1995, Vol. 20, pp. 273–297, DOI: 10.1007/BF00994018.
24. Sheykhoumousa M., Mahdianpari M., Ghanbari H., *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, Vol. 13, pp. 6308–6325, URL: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9206124> (data obrashcheniya: 03.09.2023).
25. Zhou R., Yang C., Li E., Cai X., Object-based wetland vegetation classification using multi-feature selection of unoccupied aerial vehicle RGB imagery, *Remote Sensing*, 2021, Vol. 13, No. 23, pp. 4910, DOI: 10.3390/rs13234910.
26. Starovoitov V.V., Golub U.I., *Informatika*, 2021, T. 18, No. 1, pp. 61–71, DOI: 10.37661/1816-0301-2021-18-1-61-71. (In Russ.)
27. Jenness J., Wynne J.J., Jenness Enterprises, 2007, URL: http://www.jennessent.com/arcview/kappa_stats.htm (data obrashcheniya: 07.09.2023).