



Известия Саратовского университета. Новая серия. Серия: Науки о Земле. 2026. Т. 26, вып. 3. С. 176–183


Izvestiya of Saratov University. Earth Sciences, 2026, vol. 26, iss. 3, pp. 176–183

<https://geo.sgu.ru>

<https://doi.org/10.18500/1819-7663-2026-26-3-176-183>, EDN: GSCKZO

Научная статья

УДК 502.63:528.854



Классификация угодий по степени зарастания на основе сегментации спутниковых изображений методами глубокого обучения

М. В. Огнёва, П. А. Шлапак[✉], А. И. Коноплева

Саратовский национальный исследовательский государственный университет имени Н. Г. Чернышевского, Россия, 410012, г. Саратов, ул. Астраханская, д. 83

Огнёва Марина Валентиновна, кандидат физико-математических наук, доцент, заведующий кафедрой информатики и программирования, mv_ogneva@mail.ru, <https://orcid.org/0000-0002-9828-7681>

Шлапак Павел Александрович, старший преподаватель кафедры картографии и геоинформатики, henryxiv@list.ru, <https://orcid.org/0000-0002-6418-8749>

Коноплева Алена Игоревна, магистрантка факультета компьютерных наук и информационных технологий, alena.konoplevaa@yandex.ru, <https://orcid.org/0009-0007-2640-1418>

Аннотация. В статье рассматривается применение методов глубокого обучения для автоматической сегментации спутниковых изображений с целью классификации угодий по состоянию зарастания древесно-кустарниковой растительностью. В качестве исходных данных использовались трехканальные спутниковые снимки и размеченные специалистами векторные полигоны, включающие такие классы, как поле, залежь, различные типы растительности, водные и антропогенные объекты. Для решения задачи сегментации применялись архитектуры U-Net и DeepLabv3+ с предобученным кодировщиком ResNet50 с использованием комбинированных функций потерь. В результате экспериментов наилучшие показатели качества сегментации продемонстрировала модель DeepLabv3+ с функцией ComboLoss. Практическим итогом работы стала реализация плагина для геоинформационной системы QGIS, позволяющего выполнять автоматическую сегментацию и векторизацию спутниковых данных. Предложенный подход может быть использован для мониторинга земель, анализа изменений ландшафтов и поддержки принятия решений в области природопользования.

Ключевые слова: семантическая сегментация, глубокое обучение, спутниковые снимки, дистанционное зондирование, U-Net, DeepLabv3+, землепользование, сельское хозяйство, лесная растительность

Для цитирования: Огнёва М. В., Шлапак П. А., Коноплева А. И. Классификация угодий по степени зарастания на основе сегментации спутниковых изображений методами глубокого обучения // Известия Саратовского университета. Новая серия. Серия: Науки о Земле. 2026. Т. 26, вып. 3. С. 176–183. <https://doi.org/10.18500/1819-7663-2026-26-3-176-183>, EDN: GSCKZO

Статья опубликована на условиях лицензии Creative Commons Attribution 4.0 International (CC-BY 4.0)

Article

Classification of land based on vegetation cover using deep learning methods for satellite image segmentation

M. V. Ogneva, P. A. Shlapak[✉], A. I. Konopleva

Saratov State University, 83 Astrakhanskaya St., Saratov 410012, Russia

Marina V. Ogneva, mv_ogneva@mail.ru, <https://orcid.org/0000-0002-9828-7681>

Pavel A. Shlapak, henryxiv@list.ru, <https://orcid.org/0000-0002-6418-8749>

Alyona I. Konopleva, alena.konoplevaa@yandex.ru, <https://orcid.org/0009-0007-2640-1418>

Abstract. This paper examines the application of deep learning methods for the automatic segmentation of satellite images with the aim of classifying land cover types based on their degree of vegetation cover. Three-channel satellite images and vector polygons annotated by experts were used as input data, including classes such as fields, fallow land, various types of tree and shrub vegetation, water bodies, and man-made objects. To solve the segmentation problem, the U-Net and DeepLabv3+ architectures were applied with a pre-trained ResNet50 encoder using combined loss functions. As a result of the experiments, the DeepLabv3+ model with the ComboLoss function demonstrated the best segmentation quality metrics. The practical outcome of this work was the implementation of a plugin for the QGIS geographic information system, enabling automatic segmentation and vectorization of satellite data. The proposed approach can be used for land monitoring, landscape change analysis, and decision support in the field of natural resource management.

Keywords: segmentation, deep learning, satellite imagery, remote sensing, U-Net, DeepLabv3+, landuse, agriculture, forest vegetation



For citation: Ogneva M. V., Shlapak P. A., Konopleva A. I. Classification of land based on vegetation cover using deep learning methods for satellite image segmentation. *Izvestiya of Saratov University. Earth Sciences*, 2026, vol. 26, iss. 3, pp. 176–183 (in Russian). <https://doi.org/10.18500/1819-7663-2026-26-3-176-183>, EDN: GSKCZO

This is an open access article distributed under the terms of Creative Commons Attribution 4.0 International License (CC-BY 4.0)

Введение

Методы дистанционного зондирования Земли широко используются для решения задач мониторинга сельскохозяйственных угодий, анализа растительности и исследования динамики землепользования [1–4]. Современные спутниковые системы позволяют получать изображения высокого пространственного разрешения, содержащие значительное количество информации о состоянии поверхности Земли [5, 6]. Использование дистанционных данных открывает возможности для изучения структуры ландшафтов и выявления изменений природных экосистем на больших территориях, мониторинга опасных экзогенных процессов [2, 6–8].

Традиционные методы обработки спутниковых изображений часто требуют значительных трудозатрат и основаны на ручной разметке данных специалистами. В связи с этим возрастает актуальность разработки автоматизированных методов анализа изображений. Это позволяет выполнять классификацию территорий на основе алгоритмов машинного обучения [3, 9–11].

Одним из перспективных направлений является применение методов семантической сегментации изображений, позволяющих выполнять классификацию каждого пикселя изображения и на основе этого формировать тематические карты исследуемой территории. В последние годы для решения задач сегментации широко используются сверточные нейронные сети, демонстрирующие высокую эффективность при обработке изображений различной природы, включая медицинские изображения и данные дистанционного зондирования Земли [12, 13].

Большое значение имеет автоматизированный поиск территорий, ранее использовавшихся в сельском хозяйстве, а на данный момент подвергающихся зарастанию древесно-кустарниковой растительностью. В ГОСТ 59055–2020 упоминается термин «зарастание сельскохозяйственных угодий» в качестве вида негативного воздействия (деградации) земель и ключевого критерия их неиспользования по целевому назначению¹.

Целью настоящей работы являлась разработка метода автоматической классификации угодий по состоянию зарастания на основе сегментации спутниковых изображений с использованием методов глубокого обучения.

Предшествующие исследования

Использование математических методов обработки данных дистанционного зондирования в науках о Земле имеет весьма широкое распространение. Алгоритмы различной сложности и уровня используются в самых различных областях: экологическом мониторинге для отслеживания изменений в использовании земель [1], сельском хозяйстве [4, 5, 9], мониторинге водных ресурсов и лесных массивов [2, 3, 6], выявлении экзогенных процессов и специфических форм рельефа [8, 11].

Проблема ручной идентификации объектов на спутниковых снимках остается трудоемкой и дорогостоящей [7], что стимулирует поиск эффективных алгоритмических решений. Существует достаточно большое количество работ российских и зарубежных авторов, рассматривавших задачу автоматизации идентификации характера землепользования с помощью методов машинного обучения. Многие исследователи проводили работы по классификации спутниковых снимков [3, 4, 10, 14], однако в указанных исследованиях использовались данные с мультиспектральных каналов, которые предоставляют больше информации для исследования.

Помимо этого, проводился ряд исследований, посвященных классификации земельных угодий по степени зарастания древесно-кустарниковой растительностью. Так, в работе [7] авторы предложили подход к классификации спутниковых снимков для выявления бывших сельскохозяйственных земель. Это особенно актуально на территориях, которые были заброшены в 1990-е годы и с того времени подвергались активному зарастанию древесно-кустарниковой растительностью. В исследовании [15] рассматривалось применение методов глубокого обучения для сегментации лесного покрова и оценки зарастания сельскохозяйственных угодий, подчеркивая эффективность данных подходов для работы с большими объемами данных. Интерес представляет также работа [16], в которой для идентификации восьми древесных пород использовалась сегментационная модель U-Net на фрагментах спутниковых снимков Sentinel-2, что демонстрирует потенциал методов глубокого обучения для задач классификации объектов и явлений со схожими значениями спектральных признаков.

¹ГОСТ 59055-2020. Охрана окружающей среды. Земли. Термины и определения. М. : Стандартинформ, 2020. 10 с.



Материалы и методы

В качестве исходных данных были использованы трехканальные спутниковые изображения исследуемой территории, а также векторные данные, содержащие полигоны различных типов землепользования, которые были размечены вручную специалистами по дешифрированию данных дистанционного зондирования Земли географического факультета Саратовского национального исследовательского государственного университета имени Н. Г. Чернышевского.

Выбор территории был осуществлен на основе нескольких критериев: активное ведение сельского хозяйства, наличие лесополос, лесов, а также территорий, которые относятся к залежи. Кроме того, важным фактором является распространённость проблемы зарастания ранее возделываемых сельскохозяйственных массивов. Поэтому была выбрана территория Сосковского района Орловской области. С одной стороны, она относится к зоне с плодородными черноземными почвами, здесь активно ведётся сельское хозяйство. С другой стороны, Орловская область принадлежит к северу лесостепной зоны, где не возделываемые поля будут активно подвергаться зарастанию древесно-кустарниковой растительностью.

Векторные данные представляют собой набор полигональных объектов, каждый из которых описывает участок территории с определённым типом землепользования или степенью зарастания.

На основе векторных полигонов была сформирована растровая маска классов. Для этого выполнялась процедура растеризации векторных объектов, при которой каждому пикселю изображения присваивалось значение класса, соответствующего полигону, в границах которого расположен данный пиксель. Такой подход позволил сформировать набор обучающих данных, содержащий пары спутниковых изображений и соответствующих им масок классов.

Рассматриваемые классы включали сельскохозяйственные поля, залежные земли, различные типы древесно-кустарниковой растительности, водные объекты, антропогенные территории, а также переувлажнённые и заболоченные участки. Предварительный анализ распределения площадей классов показал наличие выраженного дисбаланса данных. Наибольшую площадь снимка покрывают полигоны типа «Поле» (19629.84 га), тогда как полигоны типов «Переувлажнённая территория» (1.79 га) и «Заболоченная (сильно переувлажнённая) территория» (1.28 га) представлены значительно меньшими площадями относительно самого большого класса. Исходя из этого, были исключены из рассмотрения малочисленные классы в связи с невозможностью

увеличить их представительство. Это позволило снизить дисбаланс классов и повысить устойчивость обучения нейронной сети. Таким образом, проводилась сегментация следующих 8 классов:

- «Фон» – фоновые пиксели;
- «Поле» – территория, вовлечённая в сельскохозяйственный оборот;
- «Залежь» – территория, ранее вовлечённая в сельскохозяйственный оборот, но некоторое время не возделываемая;
- «Редкая кустарниковая растительность» – отдельные кустарники;
- «Кустарниковая и редкая древесная растительность» – заросли кустарников и отдельные деревья;
- «Древесная растительность» – древесная растительность с сомкнутыми кронами;
- «Водные объекты и прилегающие территории» – пруды, реки, озера с прибрежными частями;
- «Антропогенные объекты» – дома, постройки, сооружения.

Для формирования обучающей выборки исходные изображения и соответствующие маски классов были разделены на фрагменты размером 224×224 пикселя. Разбиение выполнялось с наложением, при этом шаг окна был равен половине его размера, что обеспечивало частичное перекрытие областей. Использование перекрывающихся окон позволило увеличить количество обучающих примеров и обеспечить более устойчивое обучение моделей сегментации при последующем применении модели к целому изображению. Чтобы исключить утечку данных, входная информация была строго поделена на две части – северную и южную.

Дополнительно неинформативные фрагменты, содержащие менее 5% пикселей целевых классов, исключались из обучающего набора данных. Такой подход позволил уменьшить влияние фоновых областей изображения и повысить информативность обучающей выборки.

Для задачи сегментации в исследовании было рассмотрено несколько архитектур нейронных сетей. В качестве наиболее подходящей была выбрана архитектура U-Net с симметричной структурой кодера и декодера. U-net позволяет не терять информацию о пространственных характеристиках объектов. Кодировщиком выступила модель ResNet50, предварительно обученная на датасете ImageNet [12, 16].

Кроме того, рассматривалась модель DeepLabV3+ с модулем Atrous Spatial Pyramid Pooling для разномасштабного извлечения признаков, что важно для пространственных данных. В качестве функций потерь в исследовании были использованы ComboLoss и WeightedComboLoss. Метрики оценки



качества сегментации, используемые в исследовании, – Intersection over Union (IoU), Dice coefficient и F1-score. Это классические метрики, используемые при сегментации изображений [13, 17].

Результаты и их обсуждение

В ходе экспериментов были обучены модели с архитектурой U-Net и DeepLabv3+, кодировщиком ResNet50 и различными функциями потерь. Сравнение результатов показало, что использование функции ComboLoss обеспечивает более высокие значения метрик сегментации по сравнению с WeightedComboLoss. Низкое качество сегментации для некоторых классов (например, редкая кустарниковая растительность) может быть связано с неполной разметкой тестовой выборки, на которой производилось тестирование качества моделей (таблица).

Визуальный анализ результатов сегментации показал, что модель DeepLabv3+ с функцией ComboLoss более корректно определяет границы объектов и обеспечивает лучшее распознавание мелких классов.

Для обработки полноразмерных спутниковых изображений применялся метод скользящего окна. Оценивая маску ошибок сегментации наилучшей модели для всего исследуемого региона (рис. 1), можно сделать вывод, что модель ошибочно предсказывала класс «Поле» при истинном классе «Залежь». Это может быть связано с недостаточным представительством последнего класса в обучающей выборке. Дополнительно на маске выделены области, отсутствующие в эталонной разметке, но предсказанные моделью на основе анализа спутникового изображения.

Несмотря на полученные результаты, качество сегментации для некоторых классов

оказалось не таким высоким, как у других, что может быть обусловлено рядом факторов.

Во-первых, существенное влияние оказывает дисбаланс классов в обучающей выборке, приводящий к снижению качества сегментации редких объектов. Но этот факт будет присутствовать всегда на наборе реальных данных.

Во-вторых, качество исходных данных для разметки также оказывает значительное влияние на результат. Модель может иметь некоторую гибкость, возможность экстраполяции, но лишь в определенных пределах. Тем не менее, качество имеющейся в распоряжении авторов разметки можно считать вполне приемлемым. Об этом косвенно говорят результаты сегментации. Основные метрики находятся выше значения 0.8, что является вполне приемлемым результатом для такого сложного набора данных, где некоторые классы достаточно схожи по спектральным признакам.

Третьим фактором является ограниченный объем размеченных данных. Для эффективного обучения глубоких нейронных сетей требуется большое количество качественно размеченных изображений, получение которых является трудоемким процессом. Следует заметить, что дальнейшее увеличение объема размеченных данных возможно и приведет к повышению устойчивости модели, но выводы о применимости используемых методов вполне можно сделать уже на этом этапе.

Для практического использования разработанного метода был создан программный модуль в виде плагина для геоинформационной системы QGIS (рис. 2). Разработанный плагин позволяет выполнять автоматическую сегментацию спутниковых изображений непосредственно в среде геоинформационной системы.

Функциональные возможности плагина включают выбор из загруженных растровых

Оценка качества сегментации моделей на тестовой выборке по каждому классу

Класс / Модель	U-Net				DeepLabv3+			
	Combloss		WeighedLoss		Combloss		WeighedLoss	
Метрики качества	Dice	IoU	Dice	IoU	Dice	IoU	Dice	IoU
Фон	0.7856	0.7476	0.6696	0.6059	0.7836	0.7425	0.7592	0.7126
Поле	0.9315	0.9014	0.8262	0.7800	0.9312	0.8951	0.8987	0.8517
Залежь	0.8212	0.8055	0.8146	0.7979	0.8386	0.8230	0.8344	0.8113
Редкая кустарниковая растительность	0.6008	0.5588	0.3857	0.3293	0.5963	0.5548	0.6364	0.5759
Кустарниковая и редкая древесная растительность	0.6627	0.6180	0.4435	0.3836	0.6926	0.6450	0.6858	0.6274
Древесная растительность (лес)	0.7800	0.7398	0.5273	0.4731	0.7982	0.7551	0.7687	0.7236
Водные объекты и прилегающие территории	0.8538	0.8376	0.8698	0.8554	0.9067	0.8904	0.8837	0.8638
Антропогенные объекты	0.8120	0.7767	0.6796	0.6487	0.8190	0.7820	0.7880	0.7427




Рис. 1. Маска ошибок сегментации спутникового изображения с использованием модели DeepLabv3+ (цвет онлайн)

слоев, выбор модели сегментации, ее применение методом скользящего окна ко всему изображению и сохранение результатов сегментации в виде растровых и векторных файлов. Полученные карты сегментации могут использоваться для дальнейшего анализа и интеграции с другими пространственными

данными. Дополнительно можно указать название муниципального образования (области, края) и название района, чтобы сохранить эти данные в векторном слое.

Достаточно простой интерфейс разработанного дополнения позволяют упростить применение модели сегментации для анализа данных




Рис. 2. Пользовательский интерфейс разработанного плагина QGIS для выполнения сегментации и векторизации спутниковых данных (цвет онлайн)

дистанционного зондирования Земли и расширить круг пользователей.

Заключение

Полученные результаты доказывают, что глубокое обучение и использование спутниковых данных позволяет проводить на достаточно высоком уровне автоматическую сегментацию территории по показателю зарастания древесно-кустарниковой растительностью.

Были использованы два вида архитектур моделей – U-Net и DeepLabv3+ с предобученным кодировщиком ResNet50. Лучшие результаты продемонстрировала модель DeepLabv3+ с комбинированной функцией потерь ComboLoss. Были выявлены возможные перспективы, точки роста дальнейших исследований – увеличение устойчивости модели за счет увеличения объема данных, работа с дисбалансом классов.

Прикладные результаты исследования – адаптация моделей глубокого обучения к геоинформационному комплексу QGIS для упрощения моделирования и расширения круга пользователей. Отдельно стоит отметить зна-

чительное увеличение скорости автоматической классификации землепользований по зарастанию древесно-кустарниковой растительностью с помощью специального плагина, который позволяет пройти весь путь от ввода спутниковых изображений до экспорта результатов в векторном формате.

Следует выделить практические результаты и сферы применения результатов исследования.

1. Мониторинг зарастания сельскохозяйственных земель

Использование данных дистанционного зондирования вместе с методами глубокого обучения позволяет вести эффективный мониторинг сельскохозяйственных земель, ненадлежащим образом эксплуатирующихся собственниками и арендаторами. Выявленные случаи зарастания древесно-кустарниковой растительностью сельскохозяйственных массивов являются основанием для вынесения предписаний органами экологического мониторинга и структурами министерства сельского хозяйства.



2. Мониторинг структуры землепользований

Достаточно важной представляется автоматизированная классификация земельных угодий в свете контроля за структурой землепользования в составе различных административных единиц – муниципальных образований, районов и даже регионов.

3. Мониторинг естественных сукцессионных процессов

Выявление зарастающих территорий и оценка степени их зарастания позволяют определить возможные перспективы использования данных участков: сохранение статуса сельскохозяйственных земель, присоединение к лесным участкам, возможное выведение из активного использования и даже создание особо охраняемых территорий.

Таким образом, представленные в исследовании методы могут активно применяться в задачах мониторинга земель, управления природными ресурсами и геоэкологических исследованиях.

Библиографический список

1. Foley J. A., DeFries R., Asner G. P., Barford C., Bonan G., Carpenter S. R., Chapin F. S., Coe M. T., Daily G. C., Gibbs H. K., Helkowski J. H., Holloway T., Howard E. A., Kucharik C. J., Monfreda C., Patz J. A., Prentice I. C., Ramankutty N., Snyder P. K. Global consequences of land use // *Science*. 2005. Vol. 309, № 5734. P. 570–574. <https://doi.org/10.1126/science.1111772>
2. Hansen M. C., Potapov P. V., Moore R., Hancher M., Turubanova S. A., Tyukavina A., Thau D., Stehman S. V., Goetz S. J., Loveland T. R., Kommareddy A., Egorov A., Chini L., Justice C. O., Townshend J. R. G. High-resolution global maps of forest cover change // *Science*. 2013. Vol. 342, № 6160. P. 850–853. <https://doi.org/10.1126/science.1244693>, EDN: SOHMPX
3. Огнева М. В., Шлапак П. А., Васильев А. А., Моисеев Д. С. Автоматическое определение лесных пород методами машинного обучения на основе обработки спутниковых снимков // *Известия Саратовского университета. Новая серия. Серия : Науки о Земле*. 2025. Т. 25, вып. 3. С. 194–200. <https://doi.org/10.18500/1819-7663-2025-25-3-194-200>, EDN: QMVWVB
4. Макаров В. З., Гусев В. А., Шлапак П. А., Решетарова Д. А. Выбор оптимального метода распознавания сельскохозяйственных культур по космоснимкам высокого разрешения (на примере саратовского Заволжья) // *Известия Саратовского университета. Новая серия. Серия : Науки о Земле*. 2020. Т. 20, вып. 3. С. 162–170. <https://doi.org/10.18500/1819-7663-2020-20-3-162-170>, EDN: EBJEPG
5. Kamilaris A., Prenafeta-Boldú F. X. Deep learning in agriculture: A survey // *Computers and Electronics in Agriculture*. 2018. Vol. 147. P. 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>, EDN: VFAIQR
6. Pekel J. F., Cottam A., Gorelick N., Belward A. S. High-resolution mapping of global surface water // *Nature*. 2016. Vol. 540, № 7633. P. 418–422. <https://doi.org/10.1038/nature20584>, EDN: YWPJEF
7. Prishchepov A. V., Radeloff V. C., Baumann M., Kuemmerle T., Müller D. Effects of institutional changes on land use: Agricultural land abandonment during the transition from state-command to market-driven economies in post-Soviet Eastern Europe // *Environmental Research Letters*. 2012. Vol. 7, № 2. P. 1–13. <https://doi.org/10.1088/1748-9326/7/2/024021>, EDN: RIEZJL
8. Федоров А. В., Шлапак П. А., Муженский Д. А. Исследование линейной эрозии путем создания уточненной цифровой модели рельефа на основе SRTM (на примере территории Хвалынского района Саратовской области) // *Известия Саратовского университета. Новая серия. Серия : Науки о Земле*. 2020. Т. 20, вып. 1. С. 36–40. <https://doi.org/10.18500/1819-7663-2020-20-1-36-40>, EDN: WLGHXN
9. Liakos K. G., Busato P., Moshou D., Pearson S., Bochtis D. Machine learning in agriculture: A review // *Sensors*. 2018. Vol. 18, № 8. Art. 2674. <https://doi.org/10.3390/s18082674>
10. Belgiu M., Drăguț L. Random forest in remote sensing: A review of applications and future directions // *ISPRS Journal of Photogrammetry and Remote Sensing*. 2016. Vol. 114. P. 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
11. Данилов В. А., Морозова В. А., Фёдоров А. В., Шлапак П. А. Открытые данные дистанционного зондирования для выявления археологических объектов // *Известия Саратовского университета. Новая серия. Серия : Науки о Земле*. 2024. Т. 24, вып. 3. С. 150–158. <https://doi.org/10.18500/1819-7663-2024-24-3-150-158>, EDN: AQYZTX
12. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // *Lecture Notes in Computer Science*. 2015. Vol. 9351. P. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
13. Chen L. C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder–decoder with atrous separable convolution for semantic image segmentation // *Proceedings of the European Conference on Computer Vision (ECCV)*. Munich, 2018. P. 833–851. https://doi.org/10.1007/978-3-030-01234-2_49
14. Kussul N., Lavreniuk M., Skakun S., Shelestov A. Deep learning classification of land cover and crop types using remote sensing data // *IEEE Geoscience and Remote Sensing Letters*. 2017. Vol. 14, № 5. P. 778–782. <https://doi.org/10.1109/LGRS.2017.2681128>, EDN: YYGEJR
15. Lee S. H., Han K. J., Lee K., Lee K. J., Oh K. Y., Lee M. J. Classification of Landscape Affected by Deforestation Using High-Resolution Remote Sensing Data and Deep-Learning Techniques // *Remote Sensing*. 2020. Vol. 12, № 20. Art. 3372. <https://doi.org/10.3390/rs12203372>, EDN: LTDPKM
16. Wagner F. H., Sanchez A., Tarabalka Y., Lotte R. G., Ferreira M. P., Aida M. P. M., Gloor E., Phillips O. L.,



Aragão L. E. O. C. Using the U-net Convolutional Network to Map Forest Types and Disturbance in the Atlantic Rainforest with Very High Resolution Images // Remote Sensing in Ecology and Conservation. 2019. Vol. 5, № 4. P. 360–375. <https://doi.org/10.1002/rse2.111>

17. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, 2016. P. 770–778. <https://doi.org/10.1109/CVPR.2016.90>

Поступила в редакцию 09.04.2026; одобрена после рецензирования 11.05.2026;
принята к публикации 16.06.2026; опубликована 30.09.2026

The article was submitted 09.04.2026; approved after reviewing 11.05.2026;
accepted for publication 16.06.2026; published 30.09.2026