

doi: 10.17586/2226-1494-2024-24-5-806-814
УДК 004.032.26, 004.932.72'1

Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам

Андрей Витальевич Мельников¹, Юрий Михайлович Полищук²,
Михаил Александрович Русанов³✉, Валерьян Ринатович Аббазов⁴,
Глеб Александрович Кочергин⁵, Матвей Андреевич Куприянов⁶,
Оксана Ахметсафаевна Байсалямова⁷, Олег Игоревич Соколов⁸

^{1,2,3,4,5,6,7,8} Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация

^{1,3,5} Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация

¹ melnikovav@uriit.ru, <https://orcid.org/0000-0002-1073-7108>

² polichukjm@uriit.ru, <https://orcid.org/0000-0002-4944-4919>

³ rusanovma@uriit.ru✉, <https://orcid.org/0000-0002-9926-4609>

⁴ abbazovvr@uriit.ru, <https://orcid.org/0009-0008-9315-2041>

⁵ kocheringa@uriit.ru, <https://orcid.org/0009-0001-4875-7489>

⁶ kupriyanovma@uriit.ru, <https://orcid.org/0000-0002-9476-2887>

⁷ baysalyamova@uriit.ru, <https://orcid.org/0009-0000-0633-3832>

⁸ sokolkovoi@uriit.ru, <https://orcid.org/0009-0006-5869-1395>

Аннотация

Введение. Исследована задача повышения оперативности обнаружения и картографирования лесных рубок по космическим снимкам с целью выявления нарушений экологического законодательства. Традиционные методы дешифрирования данных дистанционного зондирования Земли требуют больших затрат и высокой квалификации исполнителей. Для автоматизации процессов дешифрирования космических снимков разработано большое количество разнообразных методов, в том числе основанных на применении современных технологий глубокого машинного обучения. В работе проведен сравнительный анализ сверточных и трансформерных моделей нейронных сетей, перспективных для решения задач сегментации лесных рубок по летним космическим снимкам со спутника Sentinel-2. **Метод.** В проведенном исследовании для сегментации лесных рубок применялись сверточные модели U-Net++, MA-Net, 3D U-Net, FPN-ConvLSTM и трансформерные модели SegFormer, Swin-UperNet. Особенностью компьютерного эксперимента является адаптация различных моделей нейронных сетей для анализа пары разновременных многоканальных спутниковых изображений. Представлено описание исходных данных, процедура их предобработки с учетом специфики и методика формирования обучающей выборки на основе имеющегося архива космических снимков. Предложены процедуры обучения и оценки точности рассматриваемых нейросетевых моделей с использованием метрики F1. Для оценки точности выполнено сравнение результатов моделирования с традиционным методом визуального дешифрирования с применением средств геоинформационных систем. **Основные результаты.** Получены результаты компьютерного эксперимента на примере территории Ханты-Мансийского автономного округа. Сравнение моделей сегментации лесных рубок по летним космическим снимкам показало, что точность F1 для разных моделей находится в пределах от 0,409 до 0,767. Наибольшую точность показала трансформерная модель SegFormer, которая позволила обнаруживать лесные рубки, неучтенные человеком. Время обработки одной пары полноразмерных космических снимков площади размером 100 × 100 км² составило 15 мин, что в 16 раз меньше времени, требуемого специалисту для выполнения той же задачи традиционным способом. Такая скорость обработки снимков является важным показателем для мониторинга обширных лесохозяйственных территорий. **Обсуждение.** Предлагаемый метод сегментации лесных рубок, основанный на трансформерной нейронной сети SegFormer, может быть использован для решения задачи оперативного выявления и картографирования незаконных лесных рубок. Для повышения качества работы модели необходима балансировка обучающей выборки с целью

выравнивания количества снимков с полигонами рубок различной формы и размера, а также включение в выборку снимков с частичной облачностью и тенями от облаков.

Ключевые слова

картографирование лесных рубок, космические снимки, глубокое машинное обучение, нейросетевые модели, сегментация изображений, мониторинг лесных территорий

Ссылка для цитирования: Мельников А.В., Полищук Ю.М., Русанов М.А., Аббазов В.Р., Кочергин Г.А., Куприянов М.А., Байсалимова О.А., Сокольников О.И. Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 806–814. doi: 10.17586/2226-1494-2024-24-5-806-814

Comparative analysis of neural network models for felling mapping in summer satellite imagery

Andrey V. Melnikov¹, Yuri M. Polishchuk², Mikhail A. Rusanov³✉, Valerian R. Abbazov⁴, Gleb A. Kochergin⁵, Matvey A. Kupriyanov⁶, Oksana A. Baisalyamova⁷, Oleg I. Sokolkov⁸

^{1,2,3,4,5,6,7,8} Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation
^{1,3,5} Yurga State University, Khanty-Mansiysk, 628011, Russian Federation

¹ melnikovav@uriit.ru, <https://orcid.org/0000-0002-1073-7108>

² polichukjm@uriit.ru, <https://orcid.org/0000-0002-4944-4919>

³ rusanovma@uriit.ru✉, <https://orcid.org/0000-0002-9926-4609>

⁴ abbazovvr@uriit.ru, <https://orcid.org/0009-0008-9315-2041>

⁵ Kocherginga@uriit.ru, <https://orcid.org/0009-0001-4875-7489>

⁶ kupriyanovma@uriit.ru, <https://orcid.org/0000-0002-9476-2887>

⁷ baysalyamovaoa@uriit.ru, <https://orcid.org/0009-0000-0633-3832>

⁸ sokolkovoi@uriit.ru, <https://orcid.org/0009-0006-5869-1395>

Abstract

The study aimed to improve the efficiency of detecting and mapping felling using satellite imagery, in order to identify violations of environmental regulations. Traditional remote sensing data interpretation methods are labor-intensive and require high operator expertise. To automate the satellite image interpretation process, numerous approaches have been developed, including those leveraging advanced deep machine learning technologies. The presented work conducted a comparative analysis of convolutional and transformer neural network models for the segmentation of felling in summer Sentinel-2 satellite imagery. The convolutional models evaluated included U-Net++, MA-Net, 3D U-Net, and FPN-ConvLSTM, while the transformer models were SegFormer and Swin-UperNet. A key aspect was the adaptation of these models to analyze pairs of multi-temporal, multi-channel satellite images. The data preprocessing, training sample generation, and model training and evaluation procedures using the F1 metric are described. The modeling results were compared to traditional visual interpretation methods using GIS tools. Experiments on the territory of the Khanty-Mansiysk Autonomous Okrug showed that the F1 accuracy of the different models ranged from 0.409 to 0.767, with the SegFormer transformer model achieving the highest performance and detecting felling missed by human interpretation. The processing time for a 100 × 100 km² image pair was 15 minutes, 16 times faster than manual methods — an important factor for large-scale forest monitoring. The proposed SegFormer-based felling segmentation approach can be used for rapid detection and mapping of illegal logging. Further improvements could involve balancing the training dataset to include more diverse clearing shapes and sizes as well as incorporating partially cloudy images.

Keyword

felling mapping, satellite imagery, deep machine learning, neural network models, image segmentation, forest area monitoring

For citation: Melnikov A.V., Polishchuk Yu.M., Rusanov M.A., Abbazov V.R., Kochergin G.A., Kupriyanov M.A., Baisalyamova O.A., Sokolkov O.I. Comparative analysis of neural network models for felling mapping in summer satellite imagery. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 806–814 (in Russian). doi: 10.17586/2226-1494-2024-24-5-806-814

Введение

Активное освоение территорий северных регионов России, связанное с разведкой, добычей и транспортировкой углеводородного сырья и других полезных ископаемых, приводит к необходимости вырубке лесных насаждений с целью обустройства объектов обрабатывающей и транспортной инфраструктуры ресурсодобывающих предприятий. В связи с этим приоритетными направлениями в сфере охраны окружающей среды и природных ресурсов регионов являются мониторинг

лесных экосистем и задачи устойчивого управления лесным фондом региона, включая контроль несанкционированных лесных рубок.

Особую важность решения этих задач приобретает Ханты-Мансийский автономный округ (ХМАО), на территории которого функционирует Западно-Сибирский нефтедобывающий комплекс мирового уровня, поставляющий почти половину российской нефти. Большая часть территории округа, занимающего площадь 530 тыс. км², покрыто лесной растительностью, на состояние которой заметное воздействие

оказывает нефтедобыча. Кроме того, в ХМАО ведется интенсивная лесозаготовка, в результате которой вырубки подвергаются довольно обширные территории лесного фонда.

С целью контроля за вырубкой лесных насаждений на территории ХМАО с 2014 г. ведется непрерывный космический мониторинг территории лесного фонда, направленный в том числе и на оперативное выявление незаконных лесных рубок. В результате этой работы была создана база данных «Реестр изменений лесного фонда ХМАО» [1], которая содержит более 15 тыс. записей, включающих информацию о выявленных лесных рубках. Наполнение указанной базы данных осуществлялось с использованием разновременных космических снимков, дешифрирование которых проводилось традиционными методами с применением средств геоинформационной системы QGIS.

Однако эффективность традиционного подхода к выявлению лесных рубок по космическим снимкам, требующего привлечения квалифицированных специалистов для их дешифрирования, ввиду трудоемкости и высоких затрат времени оказывается относительно невысокой. По этой причине, актуальной является задача автоматизации процесса выявления лесных рубок на основе дешифрирования спутниковых изображений. Наиболее перспективными в решении этой задачи рассматриваются методы, основанные на использовании нейронных сетей для обнаружения изменений на лесных участках по космическим снимкам.

Обзор методов сегментации изображений

В [2–4] рассмотрены вопросы применения нейронных сетей для автоматизации процесса дешифрирования спутниковых изображений в задачах обнаружения изменений в состоянии лесных территорий. Отметим, что данные научные работы посвящены выявлению изменений состояния лесного фонда на территории экваториальных лесов. Учитывая особенности лесных насаждений в северных регионах России, и особенно, в Сибири, где распространены таежные леса бореального пояса с преобладанием хвойных пород деревьев, рассмотренные в [2–4], методы оперативного выявления лесных рубок по космическим снимкам на основе нейронных сетей, разработанные для экваториальных лесов, не применимы для решения поставленной в работе задачи.

В настоящее время известны единичные работы [5–7], в которых рассматриваются вопросы применения нейросетевых моделей для определения лесных рубок на северных территориях России по космическим снимкам. В [5] рассмотрено использование методов глубокого обучения для идентификации повреждений леса, в том числе и лесных рубок, на европейской территории России и Урала с использованием пар разновременных снимков Sentinel-2. На основе сравнения нескольких моделей, имеющих архитектуру U-Net, в [6] показано, что модель MobilNetv2 U-Net продемонстрировала наилучшую точность в сегментации лесных рубок на территории Иркутской области. В [6] также описано применение сверточной нейронной сети ResNet50

для определения рубок с использованием космических снимков Sentinel-2. Однако точность выявления рубок оказалась невысокой.

В [7] исследована нейросетевая модель обнаружения рубок на территории ХМАО распространенной архитектуры U-Net++, которая показала высокую эффективность при использовании зимних космических снимков Sentinel-2. По причине значительной доли лесных рубок на территории ХМАО, которые производятся в летний период, для повышения оперативности выявления таких рубок целесообразно использование летних снимков. Отметим, что выполненный в рамках настоящей работы предварительный анализ применения модели U-Net++ показал ее крайне низкую точность в задачах выявления рубок на территории ХМАО по летним снимкам.

Исходя из этого, возникает необходимость проведения сравнительного анализа известных методов машинного обучения с целью выбора нейросетевой модели, позволяющей наиболее эффективно выделять лесные рубки по паре разновременных космических снимков летнего периода на северных территориях. В результате работы является проведение сравнительного анализа известных нейросетевых моделей, пригодных для выявления лесных рубок по космическим снимкам, для определения архитектуры нейросетевой модели, обеспечивающей наиболее высокую точность обнаружения лесных рубок по оптическим снимкам Sentinel-2, полученным в летний период, на примере лесной территории ХМАО.

Исходные данные и методы

В качестве исходных данных для формирования обучающей выборки и тестирования различных нейросетевых моделей были использованы космические снимки со спутника Sentinel-2¹, обработанные до уровня 2, где каждый снимок представляет собой ортотрансформированное многоканальное изображение с атмосферной коррекцией [8]. Для обучения моделей выбраны снимки, которые имеют изображение поверхности Земли, полученные из 10 каналов с пространственным разрешением 10 и 20 м.

В настоящее время разработано и успешно применяется для сегментации изображений, в том числе и многоканальных космических снимков, достаточно большое количество различных архитектур нейронных сетей. Анализ наиболее популярных нейронных сетей показал, что в зависимости от особенностей архитектуры они могут быть сгруппированы в два класса: сверточные и трансформерные.

Сверточные нейронные сети являются особым типом искусственных нейронных сетей, которые традиционно используются для анализа данных с пространственной или временной структурой, таких как изображения, звук или видео. К этому классу, напри-

¹ Официальный сайт Sentinel Online [Электронный ресурс]. Режим доступа: sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/processing-levels/level-2, свободный. Яз. англ. (дата обращения: 28.06.2024).

мер, относятся следующие исследуемые авторами сети: U-Net++ [9, 10], MA-Net [11], 3D U-Net [9, 10], FPN-ConvLSTM [9, 12, 13], которые показали свою эффективность во многих задачах компьютерного зрения, включая классификацию изображений, детектирование объектов, сегментацию и многое другое. Основным элементом сверточной нейронной сети — сверточный слой, который применяет фильтры (ядра свертки) к входным данным. Фильтры позволяют извлекать важные признаки изображения объектов, такие как границы, формы или текстуры, сохраняя при этом пространственную информацию. За каждым сверточным слоем следует специальный слой, который уменьшает размерность данных и способствует выявлению более обобщенных и инвариантных признаков.

Трансформерные нейронные сети имеют архитектуру, адаптированную для обработки последовательностей данных, таких как тексты, аудиозаписи или временные ряды. К этому классу, например, относятся две нейронные сети, исследуемые в настоящей работе: SegFormer [14] и Swin-UperNet [15]. Главная отличительная особенность трансформерных нейронных сетей — использование механизма внимания, основная идея которого заключается в том, что трансформер обрабатывает не всю последовательность входных данных, а выявляет связи между наиболее релевантными объектами входной последовательности. Это позволяет модели распознать контекст и взаимосвязи на разных уровнях и создать более глубокие связи между элементами последовательности. Хотя трансформерные нейронные сети были разработаны в основном для обработки текстовых данных, существуют различные модификации архитектуры этих нейронных сетей, специально предназначенные для анализа и сегментации изображений.

Результаты и обсуждение

Общая схема формирования набора обучающих данных, состоящего из экспериментальных данных о лесных рубках (совокупности кадров, полученных из космических снимков) и размеченных данных (совокупности масок контуров лесных рубок для каждого кадра), для разработки модели представлена в [7]. В качестве источника информации для обучения нейронной сети использовалась база данных выявленных лесных рубок на территории ХМАО [1]. Для каждой известной лесной рубки выбиралась пара разновременных космических снимков (до и после рубки), представляющих собой ортотрансформированные изображения с атмосферной коррекцией 10 спектральных каналов с разрешением 10 и 20 м.

Далее изображения со всех спектральных каналов с разрешением 20 м с использованием нейросетевой модели DeepSentinel-2 [16] преобразовывались в изображения с пространственным разрешением 10 м. На следующем шаге формировались 20-канальные растровые изображения, которые впоследствии разрезались на кадры размером 256×256 пикселей. Таким образом, каждый сформированный кадр содержал в себе информацию о территории лесного участка до рубки и после

нее. Пример 20-канального кадра из набора обучающих данных (20-канальных изображений) представлен на рис. 1, где изображения 1–10 представляют собой спектральные каналы космического снимка, выполненного до рубки, изображения 11–20 — после рубки, изображение 21 — маска контуров лесных рубок для данной пары космических снимков.

В настоящей работе использованы модели нейронных сетей, которые принимают на вход или единичное, или последовательность RGB-изображений. При этом выполнен анализ космических снимков, представляющих 20-канальные изображения, поэтому возникла необходимость в адаптации блока входных данных для этих моделей. Это позволило обеспечить возможность обработки многоканальных снимков указанной размерности нейросетевыми архитектурами, изначально предназначенными для работы с трехканальными RGB-изображениями.

Границы векторных контуров известных лесных рубок из базы данных [1] конвертировались в растровый формат данных и далее также разрезались на кадры размером 256×256 пикселей соответственно 20-канальным кадрам космических снимков. Пример изображения маски контуров лесных рубок для 20-канального кадра представлен на рис. 1 (изображение 21).

Для подготовки набора обучающих данных использовано более 2700 пар разновременных космических снимков за летний период 2017–2022 гг., из которых было сформировано более 43 000 кадров размером 256×256 пикселей. Полученный набор кадров разделен на обучающую, валидационную и тестовую выборки, объемы которых составили 40 000, 1000 и 2000 кадров соответственно.

Обучающая выборка — набор кадров, используемый для настройки параметров модели. Эта выборка предоставляет модели информацию о различных входных данных и соответствующих им правильных ответах. Нейронная сеть обрабатывает обучающие примеры и корректирует свои веса и параметры, чтобы уменьшить ошибку предсказания. Валидационная выборка используется для оценки модели и последующей корректировки весов во время обучения, а тестовая — для итоговой оценки качества модели.

В качестве критерия для оценки точности каждой обученной модели нейронной сети применена метрика F1, рассчитанная по формуле [17]:

$$F1 = \frac{2 \times TP}{2 \times TP + FN + FP},$$

где TP (True Positive) — количество контуров лесных рубок (модель верно классифицировала как лесные рубки); FP (False Positive) — количество контуров объектов, не являющихся лесными рубками (модель ошибочно классифицировала как лесные рубки); FN (False Negative) — количество контуров лесных рубок (модель не классифицировала как лесные рубки).

Использование метрики F1 обусловлено тем, что она является достаточно информативной для сравнения качества работы различных нейросетевых моделей, и позволяет сбалансированно учитывать точность и пол-

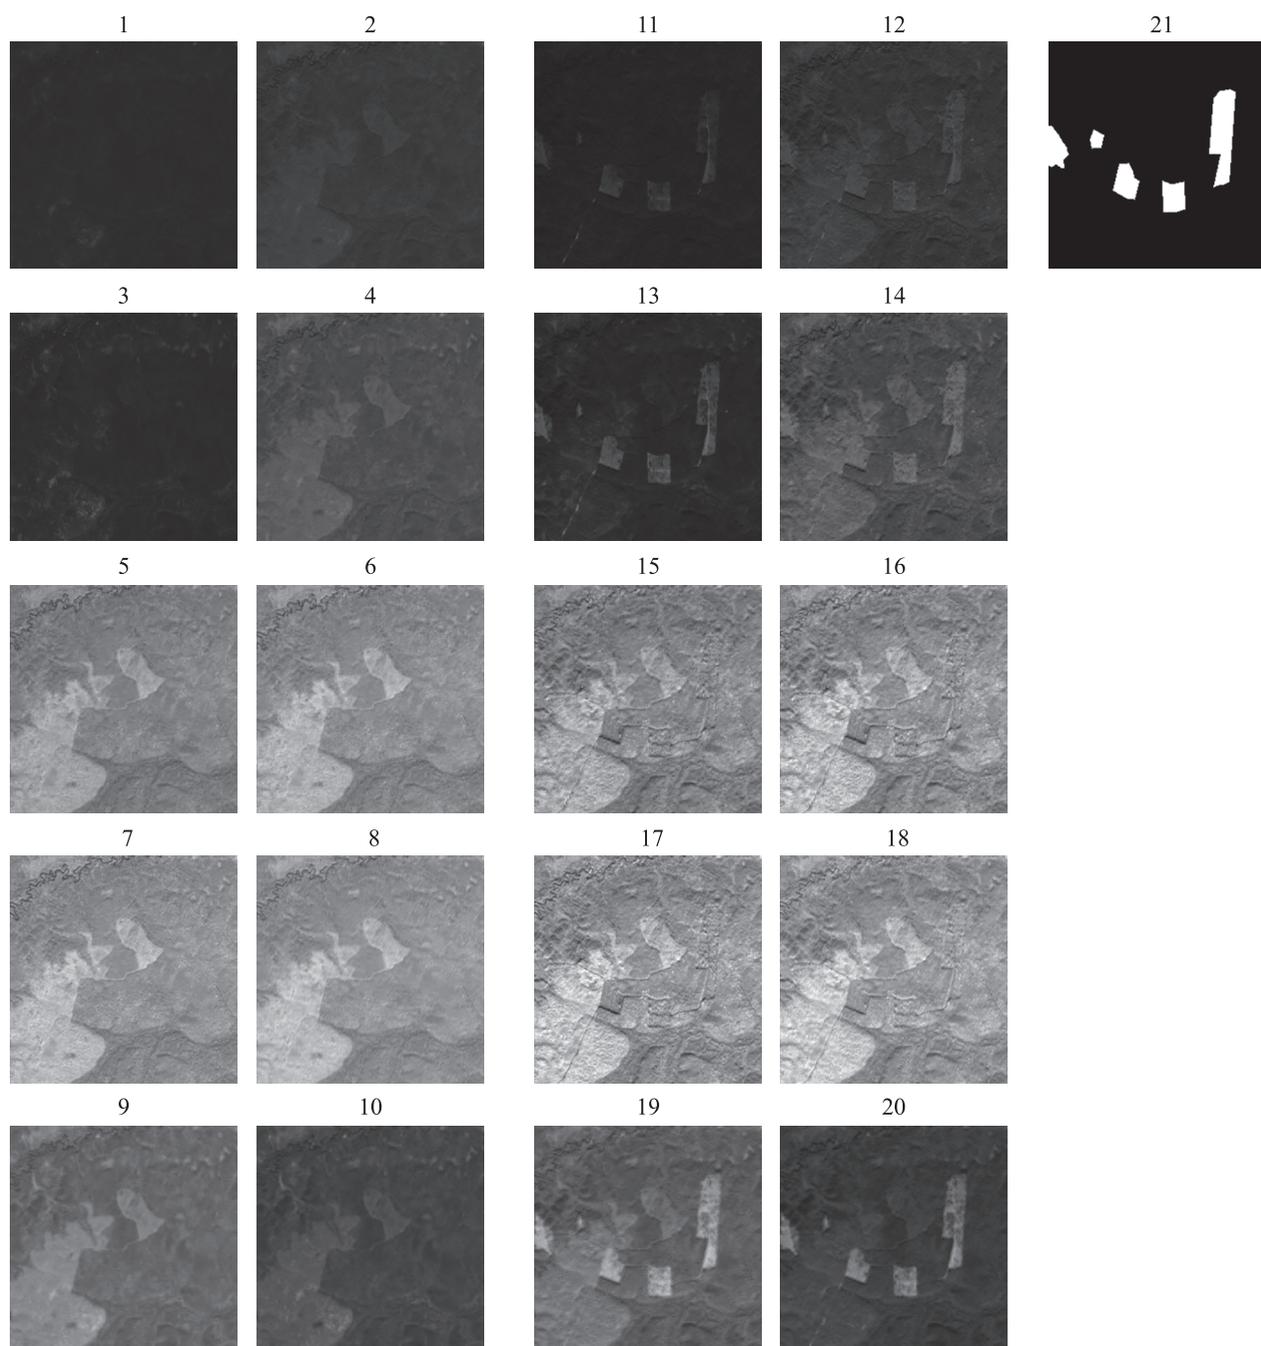


Рис. 1. Образец 20-канального кадра из набора обучающих данных и маски контуров лесных рубок (1–10 — спектральные каналы космического снимка, выполненного до рубки, 11–20 — спектральные каналы космического снимка, выполненного после появления рубки, 21 — маска контуров лесных рубок)

Fig. 1. Sample of 20-channel frame from training dataset and felling mask (1–10 — spectral channels of the satellite image made before felling, 11–20 — spectral channels of the satellite image made after felling, 21 — felling mask)

ноту сегментации изображений. Данная метрика также используется в работах [2, 4, 6, 7, 10, 12] для оценки качества нейросетевых моделей.

В ходе обучения нейросетевых моделей критерием остановки тренировки служила динамика значений функции потерь (validation loss) на валидационной выборке. Данная функция отражает ошибку модели относительно истинных значений целевой переменной. Обучение продолжалось до тех пор, пока наблюдалось последовательное снижение функции потерь. Момент остановки тренировки определялся по началу колеба-

ний или росту значений функции потерь на валидационной выборке. Для удобства сравнения моделей на рис. 2 представлены графики метрики F1 до 15-й эпохи обучения, хотя оптимальные значения данной метрики для некоторых архитектур достигались начиная с 3-й эпохи. Для дальнейшей оценки производительности моделей выбирались состояния, соответствующие прекращению снижения функции потерь на валидационной выборке при достижении максимального значения метрики F1. Как видно из рис. 2, для пяти моделей значение метрики F1 изменяется в достаточно узком

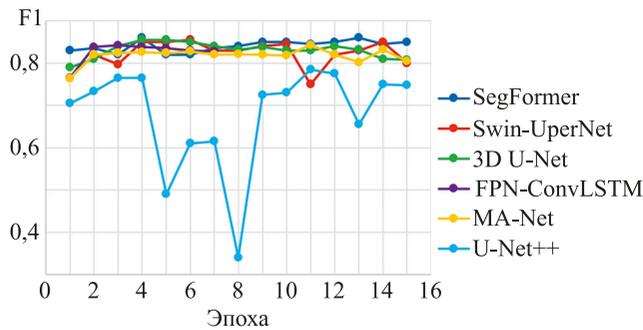


Рис. 2. Зависимости значений метрики F1 для исследуемых нейросетевых моделей от количества эпох обучения

Fig. 2. Dependence of F1 metric values for the studied neural network models vs. the number of training epochs

интервале от 0,75 до 0,9, а для модели U-Net++ — в широком диапазоне значений от 0,3 до 0,8.

После обучения исследуемых моделей проведено их сравнение на тестовой выборке с использованием метрики F1. Получены следующие результаты анализа исследуемых моделей для: SegFormer значение метрики 0,767; Swin-UperNet — 0,712; 3D U-Net — 0,676; FPN-ConvLSTM — 0,675; MA-Net — 0,475; U-Net++ — 0,409. Видно, что трансформерная нейронная сеть SegFormer показала наилучшие результаты. В то же время нейросетевая модель U-Net++, успешно используемая для сегментации лесных рубок по зимним космическим снимкам [7], продемонстрировала наихудший результат для летних снимков. Рассчитанные по тестовой выборке значения метрики F1 указывают на то, что обученная нейронная сеть SegFormer, демонстрирующая приемлемую величину точности обнаружения лесных рубок, может быть использована в практических задачах для оперативного выявления новых лесных рубок по паре летних разновременных космических снимков.

Обучение каждой из рассмотренных моделей проводилось на персональном компьютере с 8-ядерным центральным процессором IntelCore i7-9800X с тактовой частотой 3,8 ГГц, оперативной памятью 48 ГБ и двумя видеокартами NVIDIA GeForce RTX 2080Ti с 11 ГБ видеопамяти в течении 48 ч.

Рассмотрим более подробно архитектуру модели нейронной сети SegFormer [14], с лучшим результатом по выявлению лесных рубок по летним космическим снимкам. SegFormer содержит два основных модуля: кодировщика и декодировщика (рис. 3). Модуль кодировщика состоит из последовательности четырех блоков трансформеров, которые выявляют признаки, относящиеся к искомому объекту, в рассматриваемом случае — к лесной рубке. Первый блок трансформера позволяет выявить признаки высокого разрешения, а последний — признаки низкого разрешения, что повышает эффективность семантической сегментации изображения.

Модуль декодировщика последовательно выполняет три основных этапа. На этапе 1 равноуровневые признаки, полученные от кодировщика, проходят через унифицирующий многослойный перцептрон, который предназначен для преобразования размерности равноуровневых признаков из кодировщика. Напомним, что многослойный перцептрон — тип искусственной нейронной сети, состоящей из входного слоя, одного или нескольких скрытых слоев и выходного слоя, где каждый нейрон одного слоя связан со всеми нейронами следующего слоя. На этапе 2 признаки увеличиваются в размерности и объединяются в куб. На этапе 3 результирующий многослойный перцептрон объединяет признаки, находящиеся в кубе данных, полученные на этапе 2, и на основе объединенных признаков формируется слой с маской искомого объекта, т. е. применительно к поставленной задаче — маской новых выявленных рубок.

В рамках данного исследования проведен эксперимент по сравнению результатов работы обученной нейросетевой модели SegFormer и традиционного метода визуального дешифрирования для выявления новых лесных рубок по паре полноразмерных разновременных космических снимков. Для эксперимента были выбраны две пары снимков на территории площадью 10 000 км² каждая, не использовавшиеся при обучении модели. В ходе эксперимента два специалиста независимо друг от друга выявляли новые лесные рубки на каждой паре снимков, первый — с помощью обученной

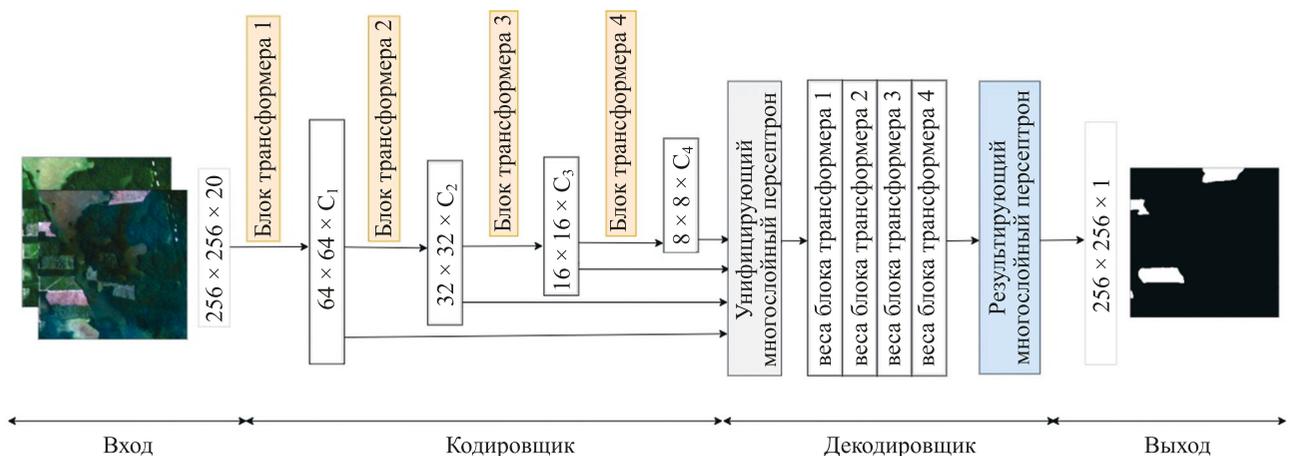


Рис. 3. Архитектура трансформерной нейронной сети SegFormer

Fig. 3. Architecture of the SegFormer transformer neural network

модели SegFormer, второй — традиционным способом визуального дешифрирования.

На следующем этапе эксперимента независимый эксперт провел сравнение результатов работы нейросетевой модели и метода визуального дешифрирования. Суммарно в ходе эксперимента получено 219 уникальных полигонов, из них 70 полигонов найдены как с использованием модели, так и традиционным визуальным способом, и действительно являлись новыми лесными рубками. Модель смогла обнаружить 6 рубок, пропущенных визуальным способом, в то же время специалист визуальным способом выявил 29 рубок, не найденных моделью. Модель также ошибочно приняла за рубки 114 полигонов, выделяя облака и тени от них или другие лесные участки, не содержащие рубок.

Хотя по результатам проведенного эксперимента модель и показала меньшую точность, чем при обучении, в основном за счет большого количества ложных срабатываний, время обработки одной пары снимков с использованием модели составило около 15 мин, в то время как специалисту для визуального дешифрирования потребовалось более 4 ч. Проведенный эксперимент продемонстрировал перспективность использования трансформерных нейросетевых моделей для автоматизации процессов дешифрирования космических снимков прежде всего за счет скорости обработки данных, что является несомненным преимуществом при анализе данных дистанционного зондирования Земли на такие обширные территории как, например, ХМАО.

Заключение

В работе представлены результаты сравнительного анализа точности и эффективности сверточных и трансформерных нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам Sentinel-2 на примере территории Ханты-Мансийского автономного округа. Результаты исследования показали, что трансформерная нейронная сеть SegFormer продемонстрировала наилучшие показатели точности выявления лесных рубок по сравнению с другими рассмотренными моделями.

Эксперимент по сравнению эффективности модели SegFormer и традиционного метода визуального дешифрирования космических снимков подтвердил перспективность использования нейросетевых методов для автоматизации процессов картографирования различных объектов, например, лесных рубок. Несмотря на то, что на текущем этапе модель SegFormer уступает традиционным методам дешифрирования по точности, она значительно превосходит их по скорости анализа космических снимков, что является важным показателем для экологического контроля обширных территорий лесных регионов, таких как Ханты-Мансийский автономный округ.

Для дальнейшего повышения точности нейросетевой модели необходимо проведение дополнительных исследований, направленных на расширение объема и улучшение качества обучающей выборки, включение в нее более разнообразных примеров лесных рубок. Также возможно исследовать влияние кадров, содержащих облака, тени от облаков и другие объекты, которые могут быть ошибочно классифицированы моделью как рубки, на качество работы нейросетевой модели.

Литература

1. Габдрахманов Р.М., Кочергин Г.А., Куприянов М.А., Хамедов В.А., Шарафутдинов Р.Р. Реестр изменений лесного фонда ХМАО — Югры. Свидетельство о регистрации базы данных RU2016620648. 2016.
2. Torres D.L., Turnes J.N., Soto Vega P.J., Feitosa R.Q., Silva D.E., Marcato Junior J., Almeida C. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images // *Remote Sensing*. 2021. V. 13. N 24. P. 5084. <https://doi.org/10.3390/rs13245084>
3. Khan S.H., He X., Porikli F., Bennamoun M. Forest change detection in incomplete satellite images with deep neural networks // *IEEE Transactions on Geoscience and Remote Sensing*. 2017. V. 55. N 9. P. 5407–5423. <https://doi.org/10.1109/tgrs.2017.2707528>
4. John D., Zhang C. An attention-based U-Net for detecting deforestation within satellite sensor imagery // *International Journal of Applied Earth Observation and Geoinformation*. 2022. V. 107. P. 102685. <https://doi.org/10.1016/j.jag.2022.102685>
5. Podoprigrorova N.S., Savchenko G.A., Rabceovich K.R., Kanev A.I., Tarasov A.V., Shikohov A.N. Forest damage segmentation using machine learning methods on satellite images // *Studies in Computational Intelligence*. 2023. V. 1120. P. 380–388. https://doi.org/10.1007/978-3-031-44865-2_41
6. Бычков И.В., Ружников Г.М., Федоров Р.К., Попова А.К., Авраменко Ю.В. Классификация космоснимков Sentinel-2 Байкальской природной территории // *Компьютерная оптика*. 2022. Т. 46. № 1. С. 90–96. <https://doi.org/10.18287/2412-6179-co-1022>
7. Мельников А.В., Кочергин Г.А., Аббазов В.Р., Байсаламова О.А., Русанов М.А., Полищук Ю.М. Нейросетевая модель для сегмен-

References

1. Gabdrakhmanov R.M., Kochergin G.A., Kupriianov M.A., Khamedov V.A., Sharafutdinov R.R. Register of changes in the forest fund of Khanty-Mansiysk Autonomous Okrug — Yugra. *Certificate of registration of the database RU2016620648*, 2016.
2. Torres D.L., Turnes J.N., Soto Vega P.J., Feitosa R.Q., Silva D.E., Marcato Junior J., Almeida C. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images. *Remote Sensing*, 2021, vol. 13, no. 24, pp. 5084. <https://doi.org/10.3390/rs13245084>
3. Khan S.H., He X., Porikli F., Bennamoun M. Forest change detection in incomplete satellite images with deep neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, vol. 55, no. 9, pp. 5407–5423. <https://doi.org/10.1109/tgrs.2017.2707528>
4. John D., Zhang C. An attention-based U-Net for detecting deforestation within satellite sensor imagery. *International Journal of Applied Earth Observation and Geoinformation*, 2022, vol. 107, pp. 102685. <https://doi.org/10.1016/j.jag.2022.102685>
5. Podoprigrorova N.S., Savchenko G.A., Rabceovich K.R., Kanev A.I., Tarasov A.V., Shikohov A.N. Forest damage segmentation using machine learning methods on satellite images. *Studies in Computational Intelligence*, 2023, vol. 1120, pp. 380–388. https://doi.org/10.1007/978-3-031-44865-2_41
6. Bychkov I.V., Ruzhnikov G.M., Fedorov R.K., Popova A.K., Avramenko Y.V. Classification of Sentinel-2 satellite images of the Baikal Natural Territory. *Computer Optics*, 2022, vol. 46, no. 1, pp. 90–96. (in Russian). <https://doi.org/10.18287/2412-6179-co-1022>
7. Melnikov A.V., Kochergin G.A., Abbazov V.R., Baisalamova O.A., Rusanov M.A., Polishchuk Yu.M. A neural network model for space image segmentation in monitoring of deforestation factors. *Bulletin*

- тации космических снимков в мониторинге факторов обезлесения территории // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. 2023. Т. 23. № 3. С. 5–15. <https://doi.org/10.14529/ctcr230301>
8. Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for Sentinel-2 // *Proceedings of SPIE*. 2017. V. 10427. P. 1042704. <https://doi.org/10.1117/12.2278218>
 9. Garnot V.S.F., Landrieu L. Panoptic segmentation of satellite image time series with convolutional temporal attention networks // *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2021. P. 4852–4861. <https://doi.org/10.1109/iccv48922.2021.00483>
 10. Rustowicz R., Cheong R., Wang L., Ermon S., Burke M., Lobell D. Semantic segmentation of crop type in Africa: A novel dataset and analysis of deep learning methods // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*. 2019. P. 75–82.
 11. Fan T., Wang G., Li Y., Wang H. MA-Net: A multi-scale attention network for liver and tumor segmentation // *IEEE Access*. 2020. V. 8. P. 179656–179665. <https://doi.org/10.1109/access.2020.3025372>
 12. Chamorro Martinez J.A., Cué La Rosa L.E., Feitosa R.Q., Sanches I.D., Happ P.N. Fully convolutional recurrent networks for multirate crop recognition from multitemporal image sequences // *ISPRS Journal of Photogrammetry and Remote Sensing*. 2021. V. 171. P. 188–201. <https://doi.org/10.1016/j.isprsjprs.2020.11.007>
 13. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W., Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting // *arXiv*. 2015. arXiv:1506.04214. <https://doi.org/10.48550/arXiv.1506.04214>
 14. Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J.M., Luo P. SegFormer: Simple and efficient design for semantic segmentation with transformers nowcasting // *arXiv*. 2021. arXiv:2105.15203. <https://doi.org/10.48550/arXiv.2105.15203>
 15. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. Swin transformer: Hierarchical vision transformer using shifted Windows // *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2021. P. 9992–10002. <https://doi.org/10.1109/iccv48922.2021.00986>
 16. Kruitwagen L. Towards DeepSentinel: An extensible corpus of labelled Sentinel-1 and -2 imagery and a general-purpose sensor-fusion semantic embedding model // *arXiv*. 2021. arXiv:2102.06260. <https://doi.org/10.48550/arXiv.2102.06260>
 17. Betzalel E., Penso C., Navon A., Fetaya E. A study on the evaluation of generative models // *arXiv*. 2022. arXiv:2206.10935. <https://doi.org/10.48550/arXiv.2206.10935>
- of the South Ural State University. Series Computer Technology, Aotimatic Control, Radio Electronics*, 2023, vol. 23, no. 3, pp. 5–15. (in Russian). <https://doi.org/10.14529/ctcr230301>
8. Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for Sentinel-2. *Proceedings of SPIE*, 2017, vol. 10427, pp. 1042704. <https://doi.org/10.1117/12.2278218>
 9. Garnot V.S.F., Landrieu L. Panoptic segmentation of satellite image time series with convolutional temporal attention networks. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 4852–4861. <https://doi.org/10.1109/iccv48922.2021.00483>
 10. Rustowicz R., Cheong R., Wang L., Ermon S., Burke M., Lobell D. Semantic segmentation of crop type in Africa: A novel dataset and analysis of deep learning methods. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshop*, 2019, pp. 75–82.
 11. Fan T., Wang G., Li Y., Wang H. MA-Net: A multi-scale attention network for liver and tumor segmentation. *IEEE Access*, 2020, vol. 8, pp. 179656–179665. <https://doi.org/10.1109/access.2020.3025372>
 12. Chamorro Martinez J.A., Cué La Rosa L.E., Feitosa R.Q., Sanches I.D., Happ P.N. Fully convolutional recurrent networks for multirate crop recognition from multitemporal image sequences. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, vol. 171, pp. 188–201. <https://doi.org/10.1016/j.isprsjprs.2020.11.007>
 13. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W., Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *arXiv*, 2015, arXiv:1506.04214. <https://doi.org/10.48550/arXiv.1506.04214>
 14. Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J.M., Luo P. SegFormer: Simple and efficient design for semantic segmentation with transformers nowcasting. *arXiv*, 2021, arXiv:2105.15203. <https://doi.org/10.48550/arXiv.2105.15203>
 15. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. Swin transformer: Hierarchical vision transformer using shifted Windows. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 9992–10002. <https://doi.org/10.1109/iccv48922.2021.00986>
 16. Kruitwagen L. Towards DeepSentinel: An extensible corpus of labelled Sentinel-1 and -2 imagery and a general-purpose sensor-fusion semantic embedding model. *arXiv*, 2021, arXiv:2102.06260. <https://doi.org/10.48550/arXiv.2102.06260>
 17. Betzalel E., Penso C., Navon A., Fetaya E. A study on the evaluation of generative models. *arXiv*, 2022, arXiv:2206.10935. <https://doi.org/10.48550/arXiv.2206.10935>

Авторы

Мельников Андрей Витальевич — доктор технических наук, профессор, директор, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск 628011, Российская Федерация; профессор, Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-1073-7108>, melnikovav@uriit.ru

Полищук Юрий Михайлович — доктор физико-математических наук, профессор, главный научный сотрудник, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, [sc 6701744203](https://orcid.org/0000-0002-4944-4919), <https://orcid.org/0000-0002-4944-4919>, polichukjm@uriit.ru

Русанов Михаил Александрович — руководитель центра, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск 628011, Российская Федерация; старший преподаватель, Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-9926-4609>, rusanovma@uriit.ru

Аббазов Валерьян Ринатович — ведущий программист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0008-9315-2041>, abbazovvr@uriit.ru

Кочергин Глеб Александрович — кандидат технических наук, руководитель центра, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация; доцент, Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0001-4875-7489>, kocheringa@uriit.ru

Authors

Andrey V. Melnikov — D.Sc., Professor, Director, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation; Professor, Yuga State University, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-1073-7108>, melnikovav@uriit.ru

Yuri M. Polishchuk — D.Sc. (Physics & Mathematics), Professor, Chief Researcher, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, [sc 6701744203](https://orcid.org/0000-0002-4944-4919), <https://orcid.org/0000-0002-4944-4919>, polichukjm@uriit.ru

Mikhail A. Rusanov — Head of the Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation 628011, Russian Federation; Senior Lecturer, Yuga State University, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-9926-4609>, rusanovma@uriit.ru

Valerian R. Abbazov — Leading Software Developer, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, 628011, Russian Federation, <https://orcid.org/0009-0008-9315-2041>, abbazovvr@uriit.ru

Gleb A. Kochergin — PhD, Head of the Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation; Associate Professor, Yuga State University, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0009-0001-4875-7489>, kocheringa@uriit.ru

Куприянов Матвей Андреевич — главный специалист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-9476-2887>, kupriyanovma@uriit.ru

Байсаямова Оксана Ахметсафаевна — главный специалист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0000-0633-3832>, baysalyamovaoa@uriit.ru

Соколов Олег Игоревич — программист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0006-5869-1395>, sokolkovoi@uriit.ru

Matvey A. Kupriyanov — Chief Specialist, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-9476-2887>, kupriyanovma@uriit.ru

Oksana A. Baisalyamova — Chief Specialist, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0009-0000-0633-3832>, baysalyamovaoa@uriit.ru

Oleg I. Sokolov — Software Developer, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, 628011, Российская Федерация, <https://orcid.org/0009-0006-5869-1395>, sokolkovoi@uriit.ru

Статья поступила в редакцию 28.06.2024
Одобрена после рецензирования 17.08.2024
Принята к печати 26.09.2024

Received 28.06.2024
Approved after reviewing 17.08.2024
Accepted 26.09.2024



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»