

Информатика и вычислительная техника Informatics and computer engineering

Научная статья

УДК 004.032.26, 004.932.72'1, 528.88

DOI: 10.14529/ctcr230301

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ СЕГМЕНТАЦИИ КОСМИЧЕСКИХ СНИМКОВ В МОНИТОРИНГЕ ФАКТОРОВ ОБЕЗЛЕСЕНИЯ ТЕРРИТОРИИ

А.В. Мельников, *MelnikovAV@uriit.ru*, <https://orcid.org/0000-0002-1073-7108>

Г.А. Кочергин, *KocherginGA@uriit.ru*

В.Р. Аббазов, *AbbazovVR@uriit.ru*

О.А. Байсалямова, *BaysalyamovaOA@uriit.ru*

М.А. Русанов, *RusanovMA@uriit.ru*, <https://orcid.org/0000-0002-9926-4609>

Ю.М. Полищук, *PolichukJM@uriit.ru*, <https://orcid.org/0000-0002-4944-4919>

*Югорский научно-исследовательский институт информационных технологий,
Ханты-Мансийск, Россия*

Аннотация. Статья посвящена важной проблеме применения нейросетевых моделей в задачах мониторинга состояния лесных территорий с использованием оптических спутниковых снимков. **Цель исследования.** Целью исследования явилась разработка нейросетевой модели лесных рубок, пригодной для автоматизации дешифрирования многоспектральных космических снимков Sentinel-2 в задачах мониторинга состояния лесных ресурсов лесодобывающего региона на примере Ханты-Мансийского автономного округа. **Материалы и методы.** Основу разработанной модели составила процедура сегментации космических снимков лесных рубок, основанная на сверточной нейронной сети глубокого обучения. Дешифрирование снимков со спутника Sentinel-2 проведено с помощью средств современной геоинформационной системы QGIS. Для подготовки набора обучающих данных было обработано более 990 пар разновременных космических снимков лесных территорий Ханты-Мансийского автономного округа за зимний (снежный) период 2018–2022 гг., с использованием которых было сформировано более 70 тыс. кадров в составе набора обучающих данных и соответствующих им масок контуров лесных рубок. **Результаты.** В результате выполненной работы создана нейросетевая модель лесных рубок, реализующая эффективную сегментацию космических снимков, что позволило автоматизировать трудоемкую процедуру дешифрирования многоспектральных снимков Sentinel-2 с целью выделения контуров лесных рубок. Полученный в работе набор обучающих данных в количестве более 70 тыс. кадров был разделен на обучающую, валидационную (проверочную) и тестовую (контрольную) выборки, объемы которых для разработки нейросетевой модели лесных рубок составили 58 000, 10 000 и 3600 кадров соответственно. Новизна разработанной модели определяется, с одной стороны, использованием для обучения нейронной сети зимних (снежных) космических снимков и, с другой стороны, применением пар разновременных снимков, полученных до и после лесной рубки. В качестве критериев для оценки точности обученной модели нейронной сети применены метрики *Recall*, *Precision* и *F-мера*, значения были рассчитаны по тестовой выборке. Рассчитанная точность выявления рубок с использованием предлагаемой модели на тестовой выборке данных по разным метрикам достигает 85–87 %. **Заключение.** Разработанная нейросетевая модель лесных рубок может быть использована в задачах мониторинга и картографирования состояния лесных ресурсов северных лесодобывающих территорий России с применением многоспектральных космических снимков Sentinel-2.

Ключевые слова: нейронные сети, космические снимки, лесные рубки, набор обучающих данных, метрика точности модели

Благодарности. Работа выполнена в рамках проекта по государственному заданию Департамента информационных технологий и цифрового развития ХМАО-Югры.

Для цитирования: Нейросетевая модель для сегментации космических снимков в мониторинге факторов обезлесения территории / А.В. Мельников, Г.А. Кочергин, В.Р. Аббазов и др. // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2023. Т. 23, № 3. С. 5–15. DOI: 10.14529/ctcr230301

A NEURAL NETWORK MODEL FOR SPACE IMAGE SEGMENTATION IN MONITORING OF DEFORESTATION FACTORS

A.V. Melnikov, MelnikovAV@uriit.ru, <https://orcid.org/0000-0002-1073-7108>

G.A. Kochergin, KocherginGA@uriit.ru

V.R. Abbazov, AbbazovVR@uriit.ru

O.A. Baisalamova, BaysalyamovaOA@uriit.ru

M.A. Rusanov, RusanovMA@uriit.ru, <https://orcid.org/0000-0002-9926-4609>

Yu.M. Polishchuk, PolichukJM@uriit.ru, <https://orcid.org/0000-0002-4944-4919>

Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia

Abstract. The article deals with the important problem of applying neural network models in the tasks of monitoring the condition of forest areas using optical satellite images. **Objective.** The objective of this research was to develop a neural network model of forest felling suitable for automation of decoding multi-spectral Sentinel-2 satellite images in forest monitoring tasks in the example of the Khanty-Mansi Autonomous Okrug. **Materials and Methods.** The basis of the developed model was the forest harvesting satellite images segmentation procedure based on the convolutional neural network of deep learning. Sentinel-2 data interpretation was done using the modern QGIS geoinformation system. Over 990 pairs of multi-temporal space images of the forest territories of Khanty-Mansi Autonomous Okrug in winter (snow) period of 2018–2022 were processed to prepare the training data set. More than 70 000 images of the training data set and corresponding masks of forest cutting contours were generated with these images. **Results.** As a result of this work, a neural network model of forest felling was created, which implements efficient segmentation of space images, which allowed automating the labor-intensive procedure of interpretation of multispectral Sentinel-2 images in order to identify forest logging contours. The set of training data totally 70 000 frames was divided into the training, validation (test) and test (control) samples, the amount of which for the development of the neural network model of forest felling was 58 000, 10 000 and 3600 frames respectively. The novelty of the model is determined, on the one hand, by the use of winter (snow) satellite images for training the neural network and, on the other hand, by the use of pairs of images acquired before and after forest felling. Recall, Precision and F-measure metrics were used as the criteria to evaluate the accuracy of the trained neural network model, and the values were calculated from the test sample. The calculated accuracy of felling detection using the proposed model on the test sample of data on different metrics reaches 85–87%. **Conclusion.** The developed neural network model of forest felling can be used for monitoring and mapping of forest resources of the northern forestry territories of Russia using multispectral Sentinel-2 satellite images.

Keywords: neural networks, satellite imagery, forest felling, training data set, model accuracy metric

Acknowledgments. The work was carried out within the framework of the project on the state assignment of the Department of Information Technology and Digital Development of the Khanty-Mansi Autonomous Okrug – Yugra.

For citation: 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 of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2023;23(3):5–15. (In Russ.) DOI: 10.14529/ctcr230301

Введение

Обезлесение территорий стало одной из глобальных экологических проблем современности, оказывающих влияние на многие аспекты жизни человека, в том числе на изменение климата как вследствие снижения поглощающей способности лесов улавливать и накапливать углекислый газ, так и непосредственного высвобождения огромного количества запасенного углерода при уничтожении лесной растительности. По оценкам экспертов, например, [1, 2], ежегодные мировые потери лесных ресурсов в последние десятилетия доходят до нескольких десятков миллионов гектаров. Активное освоение человеком природных территорий, покрытых лесами, в дополнение к возросшему количеству лесных пожаров, произошедших по вине человека, приводят

к существенному обезлесению территорий в разных странах. В связи с этим задачи мониторинга лесных экосистем, контроля незаконных рубок и устойчивого управления лесами являются приоритетными направлениями в сфере охраны окружающей среды и природных ресурсов регионов.

Более половины территории Ханты-Мансийского автономного округа (ХМАО), занимающей площадь более 530 тыс. кв. км, покрыто лесной растительностью. Активное освоение территории, связанное с разведкой, добычей и транспортировкой углеводородного сырья, приводит к необходимости вырубке лесных насаждений с целью обустройства необходимой обрабатываемой и транспортной инфраструктуры предприятий топливно-энергетического комплекса. Кроме того, в автономном округе ведется интенсивная лесозаготовка, в результате чего вырубке подвергаются довольно обширные территории лесного фонда.

С целью контроля за вырубкой лесных насаждений на территории Ханты-Мансийского автономного округа с 2014 г. ведется непрерывный космический мониторинг территории лесного фонда, направленный в том числе и на оперативное выявление незаконных лесных рубок. В результате была создана база данных «Реестр изменений лесного фонда ХМАО-Югры» [3], 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 использованием средств геоинформационной системы QGIS. Однако данный подход обладает рядом существенных недостатков, а именно: высокими требованиями к квалификации специалиста, осуществляющего дешифрирование, сравнительно низкой производительностью при обработке данных дистанционного зондирования Земли на большие площади, субъективностью и наличием ошибок дешифрирования, связанных с пропуском небольших по площади лесных рубок.

Вследствие достаточно низкой эффективности и высоких затрат при использовании традиционных методов анализа космических снимков актуальной является задача автоматизации процесса дешифрирования спутниковых изображений с целью выявления лесных рубок. Наиболее перспективными рассматриваются методы, основанные на использовании нейронных сетей для обнаружения изменений на лесных участках по космическим снимкам.

В [4–8] рассмотрены вопросы применения нейронных сетей для автоматизации процесса дешифрирования спутниковых изображений в задачах обнаружения изменений в состоянии лесных территорий. Как показывает анализ цитированных работ, большинство из них связано с экваториальными лесными территориями, на которых идут интенсивные процессы обезлесения. Специфика территории Ханты-Мансийского автономного округа определяется слаборазвитой транспортной инфраструктурой, труднодоступностью и высокой заболоченностью территории, вследствие чего рубка лесных насаждений производится преимущественно в зимний (снежный) период, который здесь длится не менее 6 месяцев в году. Поэтому методы оперативного выявления изменений лесного фонда по космическим снимкам на основе нейронных сетей, разработанные для экваториальных территорий, например, [4–8], не применимы для северных регионов. В связи с этим целью данной работы является разработка нейросетевой модели лесных рубок по оптическим космическим снимкам применительно к задачам мониторинга и картографирования лесных рубок на территории лесодобывающего региона на примере ХМАО.

1. Данные и методы

Для разработки нейросетевой модели лесных рубок была выбрана архитектура сверточной нейронной сети глубокого машинного обучения Unet++ [9], которая показала высокую эффективность в решении задач, связанных с сегментацией изображений [10–12]. Архитектура выбранной сети, адаптированная нами для обработки многоканальных изображений космических снимков размером 256 на 256 пикселей, была ориентирована на получение одноканальных изображений того же размера (рис. 1), где значения каждого пикселя изменяются в интервале от 0 до 1 и обозначают вероятность отнесения пикселя к лесной рубке.

На рис. 1 использованы англоязычные термины, принятые в научной литературе по нейронным сетям. В представленной модели сверточной нейронной сети основным вычислительным блоком является оператор свертки, обозначенный на рис. 1 $X^{i,j}$. Последовательное применение свертки на каждом шаге работы модели позволяет выделить характерные признаки лесной рубки

на космическом снимке, такие как границы, текстура, форма, цвет и др. При переходе Down-sampling происходит уменьшение размерности изображения с увеличением количества наиболее важных признаков, а при переходе Up-sampling производится увеличение размерности изображения и уменьшение количества признаков. Переход Skip connection передает изображение той же размерности, что и у входного изображения свертки. Оператор Sigmoid преобразует набор выходных значений из слоя свертки в вероятности. Это происходит путем сжатия значений в диапазон от 0 до 1, где значение 0 означает низкую вероятность, а значение 1 – высокую вероятность. Более подробное описание функционирования сверточной нейронной сети дано в [9].

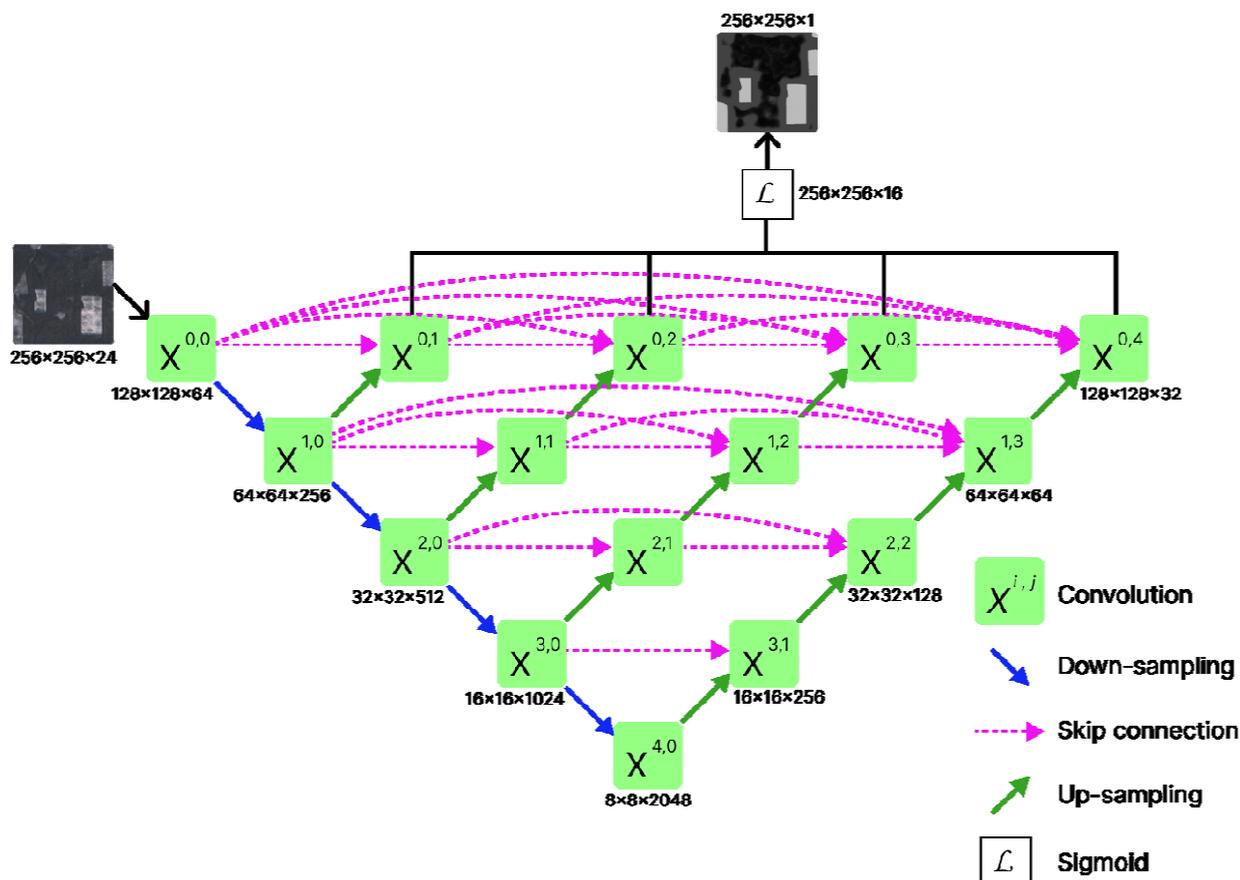


Рис. 1. Нейросетевая модель выявления лесных рубок по космическим снимкам
Fig. 1. Neural network model for detecting forest cuttings using satellite images

В качестве исходных данных для разработки модели лесных рубок были выбраны космические снимки со спутника Sentinel-2, который производит мультиспектральную съемку поверхности Земли с шириной полосы обзора 290 км и повторяемостью съемки одного и того же участка территории в северных широтах до нескольких десятков раз в год. Съемка проводится в 13 спектральных каналах с различным пространственным разрешением от 10 до 60 м. Используемые в работе снимки территории исследования были получены из открытых источников [13] и хранятся в региональном архиве космических снимков [14].

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 на рис. 2. В качестве источников исходной информации использовались указанная выше база данных выявленных лесных рубок на территории ХМАО и региональный архив космических снимков [3, 14]. Для каждой выявленной лесной рубки выбиралась пара разновременных космических снимков (до и после рубки), представляющих собой ортотрансформированные изображения с атмосферной коррекцией, пересчитанные в альbedo земной поверхности [15]. При этом с каждого снимка отбирались изображения с 12 спектральных каналов

за исключением 10-го (SWIR-Cirrus), предназначенного для обнаружения облаков и не содержащего информации о земной поверхности.



Рис. 2. Схема формирования набора обучающих данных
Fig. 2. Scheme for generating a set of training data

Далее изображения со всех спектральных каналов с разрешением 20 и 60 м с использованием модели нейронной сети глубокого обучения DeepSentinel-2 [16] преобразовывались в изображения с пространственным разрешением 10 м. На следующем шаге формировались 24-канальные растровые изображения, которые впоследствии разрезались на кадры размером 256 на 256 пикселей. Таким образом, каждый сформированный кадр содержал в себе информацию о территории лесного участка до рубки и после нее.

Границы векторных контуров выявленных лесных рубок (см. рис. 2) из базы данных конвертировались в растровый формат данных и далее разрезались на кадры размером 256 на 256 пикселей соответственно 24-канальным кадрам космических снимков. Пример отдельного кадра из набора обучающих данных (24 канала показаны как отдельные изображения) приведен на рис. 3, а маска контуров лесных рубок для него показана на рис. 4.

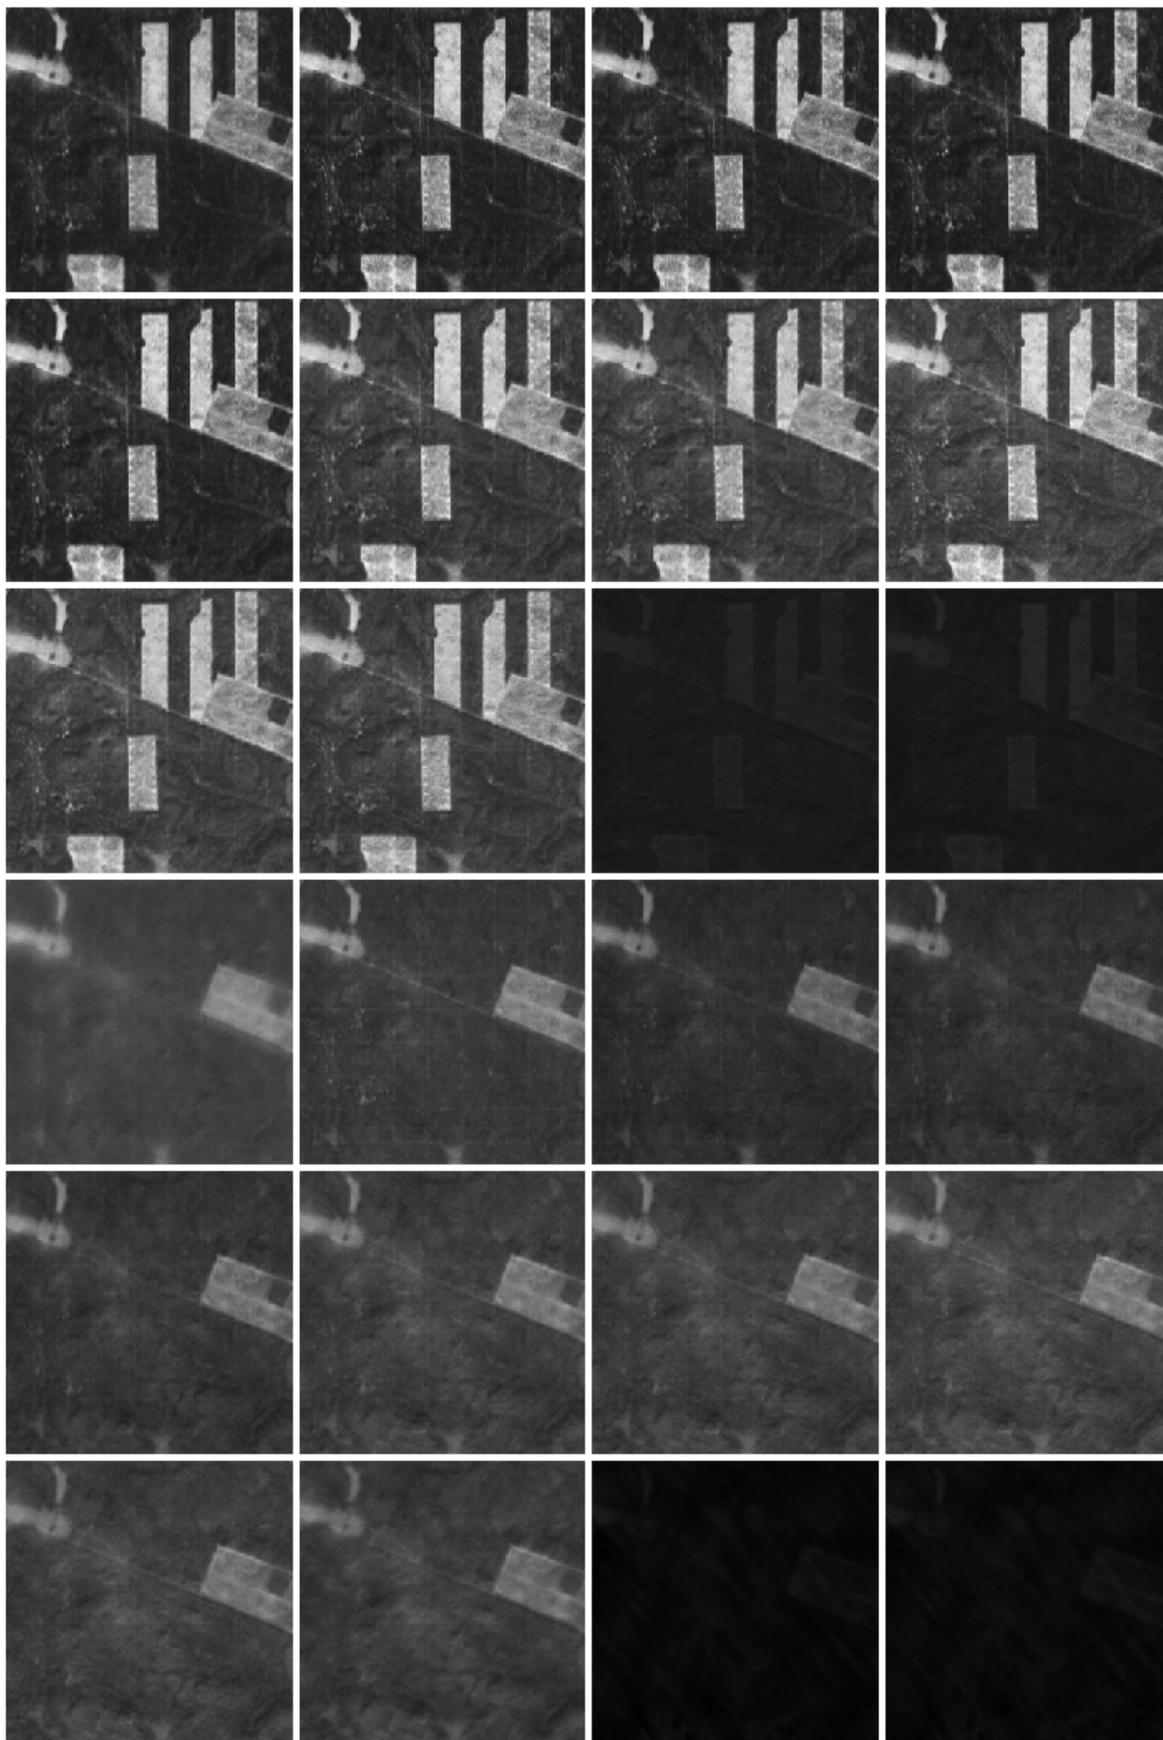


Рис. 3. Пример 24-канального кадра из набора обучающих данных
Fig. 3. An example 24-band frame from the training dataset



Рис. 4. Пример маски контуров лесных рубок из набора обучающих данных
Fig. 4. An example of a forest felling contour mask from the training dataset

2. Результаты

Для подготовки набора обучающих данных было обработано более 990 пар одновременных космических снимков за зимний (снежный) период 2018–2022 гг., из которых было сформировано более 70 тыс. 24-канальных кадров и соответствующих им масок контуров лесных рубок. Полученный в работе набор обучающих данных был разделен на обучающую, валидационную (проверочную) и тестовую (контрольную) выборки, объемы которых приведены в табл. 1.

Разделение набора обучающих данных на обучающую, валидационную и тестовую выборки

Таблица 1

Dividing the training data set into training, validation and test samples

Table 1

	Обучающая выборка Training sample	Валидационная выборка Validation sample	Тестовая выборка Test sample
Количество кадров Frames quantity	58 000	10 000	3600

Обучающая выборка используется для настройки параметров нейронной сети, количество которых в нашей модели составило 42 млн. Полученный на каждом шаге обучения модели прогноз наличия/отсутствия рубки на 24-канальном кадре сравнивается с размеченными данными (маской рубок). Затем проводится вычисление ошибки прогноза, с учетом которой производится корректировка всех параметров модели для минимизации ошибки.

Валидационная выборка используется для оценки качества нейронной сети в процессе обучения, для чего применяется метрика *IoU* (Intersection over Union) как мера оценки точности обработки изображения. Она вычисляется как отношение площади пересечения двух областей (область, которая была выделена моделью как рубка, и область реальной рубки на изображении) к их объединению и используется для сравнения результатов сегментации с размеченными данными. Чем ближе значение *IoU* к 1, тем лучше качество сегментации. В нашей работе процесс обучения занял 15 эпох и был остановлен по достижении разности значений метрики *IoU* в 14-й и 15-й эпохах менее 0,001. Итоговое значение метрики в результате обучения модели составило 0,858.

Тестовая выборка используется для оценки качества работы модели, построенной на основе обучающей выборки, и для проверки ее способности делать прогноз на новых данных. Она представляет собой набор незнакомых для модели данных, не используемых ранее в процессе обучения и валидации модели. В качестве критериев для оценки точности обученной модели нейронной сети нами применены метрики *Recall*, *Precision* и *F-мера*, значения которых, рассчитанные по тестовой выборке, приведены в табл. 2. Как видно из табл. 2, исследованные метрики дают близкие и достаточно высокие оценки, что позволяет использовать обученную нейронную сеть в практических задачах для картографирования новых лесных рубок по паре космических снимков.

Таблица 2
Рассчитанные значения точности модели по разным метрикам
Table 2
Calculated model accuracy values for different metrics

Метрика Metrics	<i>Recall</i>	<i>Precision</i>	<i>F-мера</i>
Значение Value	0,85	0,87	0,85

Результат сегментирования лесных рубок по паре разновременных космических снимков зимнего периода с использованием разработанной нейросетевой модели показан на рис. 5. Заметим, что показанные на рис. 5 контуры рубок, определенные нейронной сетью, совпадают с контурами, выявленными оператором.

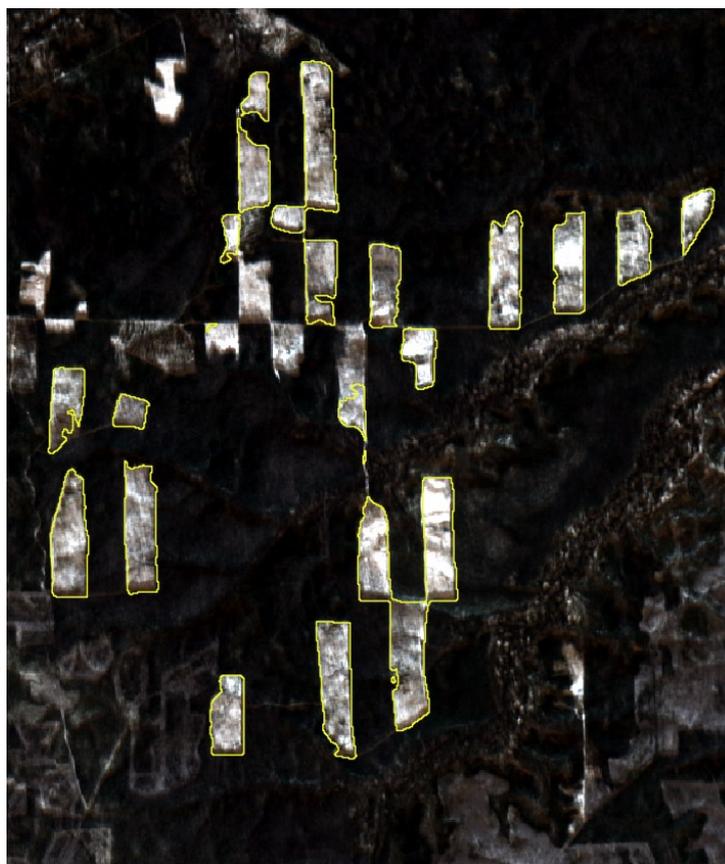


Рис. 5. Результат сегментирования лесных рубок по космическому снимку
Fig. 5. The result of forest felling segmentation by satellite image

Обучение и тестирование нейронной сети проводилось на персональном компьютере с 8-ядерным центральным процессором Intel Core i7-9800X частотой 3,8 ГГц, оперативной памятью 48 Гб и двумя видеокартами NVIDIA GeForce RTX 2080Ti 11 Гб видеопамати и заняло 2 суток.

Заключение

В статье предложена модель выявления лесных рубок на основе сверточной нейронной сети, позволяющая автоматизировать процедуры выявления и картографирования лесных рубок по космическим снимкам на территории лесного региона на примере Ханты-Мансийского автономного округа – Югры. Новизну предложенной модели определяют, во-первых, использование зимних (снежных) космических снимков для обучения нейронной сети и, во-вторых, применение пар разновременных снимков, полученных до и после лесной рубки. Приведена схема формирования обучающего набора данных для обучения нейронной сети. Для этого использованы данные

о реальных лесных рубках, дешифрованные по спутниковым снимкам Sentinel-2, полученным за зимний период 2018–2022 гг. Проведена оценка точности модели с использованием известных метрик. Показано, что точность выявления лесных рубок с помощью разработанной модели достигает 85–87 %.

Список литературы

1. GlobalForestWatch. Global Annual Tree cover loss. URL: <https://gfw.global/40kCKzS> (дата обращения: 28.03.2023).
2. FAO. Global Forest Resources Assessment 2020. URL: <https://doi.org/10.4060/ca8753en> (дата обращения: 28.03.2023).
3. Свидетельство о государственной регистрации базы данных № 2016620648 Российская Федерация. Реестр изменений лесного фонда ХМАО-Югры / П.М. Габдрахманов, Г.А. Кочергин, М.А. Куприянов [и др.]; заявитель автономное учреждение Ханты-Мансийского автономного округа – Югры «Югорский научно-исследовательский институт информационных технологий». № 2016620412; заявл. 06.04.2016; опублик. 23.05.2016.
4. Large-scale oil palm tree detection from high-resolution satellite images using two-stage convolutional neural networks / W. Li, R. Dong, H. Fu, L. Yu // *Remote Sensing*. 2018. Vol. 11, no. 1. P. 11. DOI: 10.3390/rs11010011
5. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images / D.L. Torres, J.N. Turnes, P.J.S. Vega et al. // *Remote Sensing*. 2021. Vol. 13, no. 24. P. 5084. DOI: 10.3390/rs13245084
6. Forest change detection in incomplete satellite images with deep neural networks / S.H. Khan, X. He, F. Porikli, M. Bennamoun // *IEEE Transactions on Geoscience and Remote Sensing*. 2017. Vol. 55, no. 9. P. 5407–5423. DOI: 10.1109/TGRS.2017.2707528
7. 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. P. 102685. DOI: 10.1016/j.jag.2022.102685
8. Classification of landscape affected by deforestation using high-resolution remote sensing data and deep-learning techniques / S.H. Lee, K.J. Han, K. Lee et al. // *Remote Sensing*. 2020. Vol. 12, no. 20. P. 3372. DOI: 10.3390/rs12203372
9. Unet++: A nested u-net architecture for medical image segmentation / Z. Zhou, M.M.R. Siddiquee, N. Tajbakhsh, J. Liang // *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4*. Springer International Publishing, 2018. P. 3–11. DOI: 10.1007/978-3-030-00889-5
10. Jiang Y., Zhong C., Zhang B. AGD-Linknet: A Road Semantic Segmentation Model for High Resolution Remote Sensing Images Integrating Attention Mechanism, Gated Decoding Block and Dilated Convolution // *IEEE Access*. 2023. Vol. 11. P. 22585–22595. DOI: 10.1109/ACCESS.2023.3253289
11. Doha R., Al Hasan M., Anwar S. Semantic Segmentation Approaches in Crop Row Detection // *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, 2022. P. 2224–2230. DOI: 10.1109/BigData55660.2022.10021091
12. Ensemble Learning based on Classifier Prediction Confidence and Comprehensive Learning Particle Swarm Optimisation for Medical Image Segmentation / T. Dang, T.T. Nguyen, J. McCall, A.W.C. Liew // *2022 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE, 2022. P. 269–276. DOI: 10.1109/SSCI51031.2022.10022114
13. Copernicus Sentinel-2 data 2015, processed by ESA. URL: <https://scihub.copernicus.eu/> (дата обращения: 02.03.2023).
14. Свидетельство о государственной регистрации базы данных № 2016620923 Российская Федерация. Архив космических снимков / П.М. Габдрахманов, Г.А. Кочергин; заявитель автономное учреждение Ханты-Мансийского автономного округа – Югры «Югорский научно-исследовательский институт информационных технологий». № 2016620615; заявл. 10.05.2016; опублик. 06.07.2016. EDN RRGSPX.
15. Sentinel-2 processing level-2. URL: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/processing-levels/level-2> (дата обращения: 02.03.2023).

16. Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural net-work / C. Lanaras, J. Bioucas-Dias, S. Galliani et al. // *ISPRS Journal of Photogrammetry and Remote Sensing*. 2018. Vol. 146. P. 305–319. DOI: 10.1016/j.isprsjprs.2018.09.018

References

1. GlobalForestWatch. Global Annual Tree cover loss. Available at: <https://gfw.global/40kCKzS> (accessed 28.03.2023).
2. FAO. Global Forest Resources Assessment 2020. Available at: <https://doi.org/10.4060/ca8753en> (accessed 28.03.2023).
3. Gabdrakhmanov R.M., Kochergin G.A., Kupriyanov M.A. et al. *Reestr izmeneniy lesnogo fonda KhMAO-Yugry* [Register of Changes in the Forest Fund of Khanty-Mansiysk Autonomous Okrug – Ugra]. Certificate of state registration of the database no. 2016620648 Russian Federation; no. 2016620412; decl. 06.04.2016; publ. 23.05.2016. (In Russ.)
4. Li W., Dong R., Fu H., Yu L. Large-scale oil palm tree detection from high-resolution satellite images using two-stage convolutional neural networks. *Remote Sensing*. 2018;11(1):11. DOI: 10.3390/rs11010011
5. Torres D.L., Turnes J.N., Vega P.J.S., 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;13(24):5084. DOI: 10.3390/rs13245084
6. 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;55(9):5407–5423. DOI: 10.1109/TGRS.2017.2707528
7. 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;107:102685. DOI: 10.1016/j.jag.2022.102685
8. 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;12(20):3372. DOI: 10.3390/rs12203372
9. Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. Unet++: A nested u-net architecture for medical image segmentation. In: *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4*. Springer International Publishing; 2018. P. 3–11. DOI: 10.1007/978-3-030-00889-5
10. Jiang Y., Zhong C., Zhang B. AGD-Linknet: A Road Semantic Segmentation Model for High Resolution Remote Sensing Images Integrating Attention Mechanism, Gated Decoding Block and Dilated Convolution. *IEEE Access*. 2023;11:22585–22595. DOI: 10.1109/ACCESS.2023.3253289
11. Doha R., Al Hasan M., Anwar S. Semantic Segmentation Approaches in Crop Row Detection. In: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE; 2022. P. 2224–2230. DOI: 10.1109/BigData55660.2022.10021091
12. Dang T., Nguyen T.T., McCall J., Liew A.W.C. Ensemble Learning based on Classifier Prediction Confidence and Comprehensive Learning Particle Swarm Optimisation for Medical Image Segmentation. In: *2022 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE; 2022. P. 269–276. DOI: 10.1109/SSCI51031.2022.10022114
13. Copernicus Sentinel-2 data 2015, processed by ESA. Available at: <https://scihub.copernicus.eu/> (accessed 02.03.2023).
14. Gabdrakhmanov R.M., Kochergin G.A. *Arkhiv kosmicheskikh snimkov* [Archive of space images]. Certificate of state registration of the database no. 2016620923 Russian Federation; no. 2016620615; decl. 10.05.2016; publ. 06.07.2016. (In Russ.)
15. Sentinel-2 processing level-2. Available at: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/processing-levels/level-2> (accessed 02.03.2023).
16. Lanaras C., Bioucas-Dias J., Galliani S., Baltsavias E., Schindler K. Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural net-work. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2018;146:305–319. DOI: 10.1016/j.isprsjprs.2018.09.018

Информация об авторах

Мельников Андрей Витальевич, д-р техн. наук, проф., директор, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; MelnikovAV@uriit.ru.

Кочергин Глеб Александрович, канд. техн. наук, руководитель центра космических услуг, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; KocherginGA@uriit.ru.

Аббазов Валерьян Ринатович, программист центра информационно-аналитических систем, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; AbbazovVR@uriit.ru.

Байсалимова Оксана Ахметсафаевна, главный специалист центра космических услуг, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; BaysalyamovaOA@uriit.ru.

Русанов Михаил Александрович, руководитель центра информационно-аналитических систем, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; RusanovMA@uriit.ru.

Полищук Юрий Михайлович, д-р физ.-мат. наук, проф., главный научный сотрудник центра космических услуг, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; PolichukJM@uriit.ru.

Information about the authors

Andrey V. Melnikov, Dr. Sci. (Eng.), Prof., Director, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; MelnikovAV@uriit.ru.

Gleb A. Kochergin, Cand. Sci. (Eng.), Head of the Space Service Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; KocherginGA@uriit.ru.

Valeriy R. Abbazov, Programmer of the Center for Information and Analytical Systems, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; AbbazovVR@uriit.ru.

Oksana A. Baisalyamova, Chief Specialists of the Space Service Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; BaysalyamovaOA@uriit.ru.

Mikhail A. Rusanov, Head of the Center for Information and Analytical Systems, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; RusanovMA@uriit.ru.

Yury M. Polischuk, Dr. Sci. (Phys. and Math.), Prof., Chief Researcher of the Space Service Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; PolichukJM@uriit.ru.

Статья поступила в редакцию 30.03.2023

The article was submitted 30.03.2023