

УДК 004.932

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ ОБНАРУЖЕНИЯ НАВОДНЕНИЙ ПО ДАННЫМ КОСМИЧЕСКОГО АППАРАТА «SENTINEL-2»

А. С. Вендин, студент РГРТУ, техник НИОКР НИИ «Фотон» РГРТУ, Рязань, Россия;
orcid.org/0009-0005-1379-5580, e-mail: vendin0505@mail.ru

С. А. Ларюков, аспирант РГРТУ, м.н.с. НИИ «Фотон» РГРТУ, Рязань, Россия;
orcid.org/0009-0009-9082-1454, e-mail: foton@rsreu.ru

Рассматривается задача сегментации наводнений и водных объектов по данным спутниковых снимков космического аппарата «Sentinel-2». Целью работы является создание программных средств, позволяющих в автоматическом режиме обеспечивать точный контроль за водными объектами путём использования данных дистанционного зондирования Земли и методов искусственного интеллекта. В работе выполнен анализ известных способов решения задачи и выявлены их недостатки, что объясняет актуальность новых исследований в этом направлении. В связи с ограниченной применимостью существующих подходов, а также низким качеством разметки в общедоступных наборах данных предложен нейросетевой алгоритм, основанный на архитектуре «Lanku U-Net» и использующий самостоятельно подготовленный набор данных для обучения. В результате исследования были решены следующие задачи: подготовка и разметка мультиспектральных изображений, полученных со спутника «Sentinel-2», содержащих признаки наводнений в российских регионах; обучение модели для обнаружения водных объектов; оценка качества работы модели с использованием метрик accuracy, loss, precision, recall; обнаружение наводнений с использованием маски постоянной воды. Приводятся численные показатели качества сегментации и результаты проведённых экспериментов, демонстрирующие эффективность полученной технологии.

Ключевые слова: свёрточные нейронные сети, машинное обучение, сегментация водных объектов, автоматическое обнаружение наводнений, обработка данных дистанционного зондирования Земли.

DOI: 10.21667/1995-4565-2026-95-192-201

Введение

Водные объекты, такие как моря, реки, озёра, являются неотъемлемой частью глобальной климатической системы. Изучение поверхностных водных объектов и определение их пространственных границ имеют большое значение для управления водными ресурсами и понимания гидрологических процессов. Кроме того, на территории Российской Федерации ежегодно происходит до 70 крупных наводнений [1]. Для предотвращения ущерба и принятия соответствующих мер необходимы достоверные и своевременные сведения о зонах затопления.

Одним из способов определения границ водных объектов является анализ данных дистанционного зондирования Земли. Существующие подходы распознавания воды на спутниковых снимках можно разделить на пороговые и нейросетевые.

Алгоритмы обнаружения водных объектов

Пороговые алгоритмы основаны на использовании водных индексов, таких как NDWI (Normalized Difference Water Index) [2], Multi-Band Water Index (MBWI) [3], Automated Water Extraction Index (AWEI) [4]. После вычисления индекса выбирается пороговое значение и происходит бинарная классификация пикселей изображения. Оптимальный порог в таких алгоритмах, как правило, подбирается с помощью метода Оцу [5], минимизирующего среднюю ошибку сегментации. Но на практике единый порог для всего изображения неэффективен, поскольку он может изменяться в зависимости от освещённости, угла съёмки, атмосферных условий и состава воды [6]. На рисунке 1 представлен результат распознавания воды, полученный с помощью индекса NDWI и метода Оцу. Границы воды на маске не соответствуют реальным водным объектам.




Рисунок 1 – Результат распознавания воды, полученный с помощью NDWI и метода Оцу
Figure 1 – Water recognition result obtained using NDWI and the Otsu method

Для устранения недостатков простых пороговых алгоритмов были разработаны более совершенные подходы. Так, авторы работ [1, 7] предлагают использовать дерево решений и комбинации водных индексов для распознавания воды. Вместо бинарной классификации на два типа пикселей: вода/не вода используется понятие водной фракции, которое показывает степень содержания воды в пикселе. Чем выше значение водной фракции, тем с большей степенью уверенности можно считать, что пиксель относится к классу воды. Такой подход даёт более приемлемые результаты, чем простое применение водных индексов с методом Оцу, но по-прежнему не является точным.

На рисунке 2 представлен результат распознавания водных объектов с помощью дерева решений. На представленном изображении отчётливо видно, что крупные области водных объектов были распознаны как облака, а извилистые части реки в центре изображения вообще не были распознаны как пиксели, содержащие признаки воды.

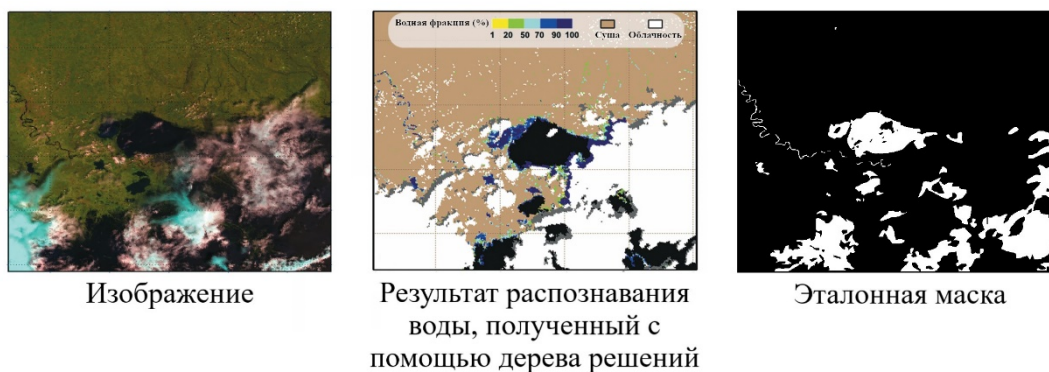


Рисунок 2 – Результат распознавания воды, полученный с помощью дерева решений
Figure 2 – Water recognition result obtained using decision tree

Данные проблемы приводят к необходимости использования подходов на основе нейронных сетей, которые способны учитывать не только спектральную, но и пространственно-текстурную информацию (контекст, форму объектов), способствуя повышению точности в сложных сценариях.

Авторы работы [8] предлагают использовать набор данных worldfloods и обученную на нём нейросеть «U-Net». Однако при детальном рассмотрении изображений этого набора данных обнаруживается его серьёзный недостаток: существенная часть изображений имеют некачественные маски, водные объекты на которых либо не выделены полностью, либо не выделены совсем. Соответственно и нейросеть «U-Net», обученная на таком наборе данных, работает неточно. На рисунке 3 представлено одно из изображений набора данных worldfloods. Маска из набора данных worldfloods не соответствует водным объектам на изображении, а результат работы «U-Net» содержит большой объём ошибочно сегментированных областей.




Рисунок 3 – Результат распознавания воды, полученный с помощью нейросети «U-Net» и набора данных worldfloods

Figure 3 – Water recognition result obtained using «U-Net» and worldfloods dataset

Нейросетевой алгоритм обнаружения водных объектов

Обобщая современное состояние научной проблемы, было принято решение обучить нейросеть на самостоятельно подготовленном наборе данных, но вместо архитектуры «U-Net» использовать её модификацию под названием «Lanky U-Net», которая призвана ускорить время обработки изображения, сохранив качество сегментации [9]. Решаемая задача формулируется следующим образом: для каждого пикселя мультиспектрального изображения со спутника необходимо определить, относится он к водному объекту или нет. Пусть $B_u = \{b(m, n)\}$ – множество всех пикселей изображения, где m – номер столбца, n – номер строки, u – номер спектрального канала. Функция $I_w(b(m, n))$ указывает на принадлежность пикселя к водному объекту:

$$I_w(b(m, n)) = \begin{cases} 1, & \text{если } b(m, n) \text{ принадлежит водному объекту,} \\ 0, & \text{иначе.} \end{cases}$$

Тогда множество пикселей, распознанных как водные объекты $S = \{b(m, n) \mid I_w(b(m, n)) = 1\}$.

Также для каждого пикселя водного объекта необходимо определить, относится он к наводнению, или является постоянной водой. С точки зрения математики, задача сводится к минимизации функции потерь (loss), рассчитываемой по формуле бинарной кросс-энтропии [10]:

$$loss = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)], \quad (1)$$

где N – количество рассматриваемых пикселей, $y_i \in \{0, 1\}$ – истинная метка класса для i -го пикселя (1 – водный объект, 0 – иное), $p_i \in [0, 1]$ – вероятность, предсказанная моделью, что i -й пиксель принадлежит классу водного объекта.

Показатель функции потерь является ключевым критерием для выбора результатов, получаемых в ходе обучения.

Решение поставленной задачи происходит согласно следующим этапам.

1. Подготовка набора данных на основе снимков космического аппарата «Sentinel-2».
2. Формирование масок воды с использованием индекса NDWI.
3. Обучение модели «Lanky U-Net», оценка её точности.
4. Сегментация наводнений на основе масок постоянной воды и масок, полученных в результате работы нейросети.

В роли источника для поиска исходных изображений выступает веб-сервис Sentinel-Hub [11], а в качестве средства загрузки – открытое облачное хранилище Amazon Web Services Sentinel 2 L2A [12]. Для формирования обучающего набора данных выбираются мультиспектральные изображения, охватывающие регионы России от Центральной части до Дальнего

Востока. Загружаются только необходимые каналы изображений: канал 3 (543-578 нм), канал 4 (650-680 нм), канал 8 (785-899 нм), канал 11 (1565-1655 нм). Такой набор каналов предоставляет информацию, которой достаточно для корректного обнаружения водных объектов [8]. Остальные каналы съёмочной аппаратуры космического аппарата «Sentinel-2» не используются, так как в них не содержится данных, позволяющих сегментировать водные объекты. Такой подход экономит пространство хранилища и ускоряет процесс работы нейросети по сравнению с использованием всех каналов. Набор данных охватывает сюжеты с различными условиями, включающими облачность, водные объекты среди городской застройки, сложные формы притоков рек. Это необходимо для того, чтобы обученная нейросеть показывала точную работу при разных сценариях использования.

Маски водных объектов формируются на основе водного индекса NDWI [2], который вычисляется по значениям яркости в каналах 3 и 8 по формуле

$$NDWI = \frac{B_3 - B_8}{B_3 + B_8}.$$

Для каждого изображения пороговая величина подбирается индивидуально с целью получения как можно более точного выделения водных объектов при минимизации ложных срабатываний. Далее оператором в графическом редакторе удаляются неправильно сегментированные фрагменты, добавляются недостающие. Сочетание индекса NDWI и ручной разметки существенно ускоряет построение масок.

Полученные изображения, состоящие из каналов 4, 8, 11, и маски водных объектов разбиваются с перекрытием на тайлы (фрагменты) размером 512 на 512 пикселей. Итоговый набор данных включает 8000 тайлов и соответствующих им масок водных объектов. Выборка разбивается на обучающую и валидационную в соотношении 80 % на 20 % соответственно. Такое решение обеспечивает достаточный объём данных для обучения и объективную оценку обучающей способности модели. Тестовые изображения формируются аналогично во время обучения нейросети и образуют 800 тайлов.

Для сегментации используется нейросетевая архитектура «Lanku U-Net», являющаяся модификацией классической «U-Net», адаптированной под задачу бинарной классификации. «Lanku U-Net» позволяет при объёме вычислений в 5,5 раза меньше, чем у «U-Net», достигать того же качества сегментации. Для обновления параметров нейронной сети в процессе обучения используется алгоритм оптимизации Adam [13], в качестве функции потерь применяется бинарная кросс-энтропия (1).

В результате работы нейросети формируется маска водных объектов. Функция $I_{pw}(b(m,n))$ указывает на принадлежность пикселя к постоянному водному объекту:

$$I_{pw}(b(m,n)) = \begin{cases} 1, & \text{если } b(m,n) - \text{постоянная вода,} \\ 0, & \text{иначе.} \end{cases}$$

Тогда множество пикселей постоянной воды определяется как $Q = \{b(m,n) | I_{pw}(b(m,n)) = 1\}$.

R – искомое множество пикселей, относящихся к наводнению, находится как разность множеств S (обнаруженная вода) и Q (постоянная вода):

$$R = S \setminus Q.$$

Экспериментальные исследования

Для обучения нейросети в качестве языка программирования выбран Python (версия 3.14.0), который предоставляет доступ к фреймворку машинного обучения TensorFlow (версия 2.20.0) с API Keras, который значительно упрощает процесс разработки. Кроме того, корректную работу скриптов обучения и работы модели поддерживают библиотеки numpy (версия 2.4.0), rasterio (версия 1.5.0), matplotlib (версия 3.10.7), pandas (версия 2.3.2).

Обучение модели осуществляется в облачном сервисе Google Colab [14]. Причину использования этого ресурса определяют вычислительные мощности, предоставляемые пользователю: графический ускоритель NVIDIA T4 существенно ускоряет обучение. Чтобы обучать нейросеть в Google Colab, необходимо выгрузить набор данных на диск, место на котором ограничено 16 Гб. В целях повышения производительности и снижения количества передаваемых данных в Google Colab изображения и маски сжимаются без потерь по алгоритму Deflate [15].

Продолжительность обучения составляет 289 эпох, на 250 эпохе скорость обучения понижается в два раза, чтобы повысить финальную точность модели. В качестве результата принята 269 эпоха, так как на ней удалось получить лучшее значение функции потерь на валидационном наборе данных.

Модель демонстрирует высокое качество сегментации. По результатам обучения были получены показатели, представленные в таблице 1.

Таблица 1 – Показатели обучения

Table 1 – Learning results

| Набор данных | accuracy | loss | precision | recall |
|---------------|----------|--------|-----------|--------|
| Обучающий | 0,9942 | 0,0141 | 0,9863 | 0,9858 |
| Валидационный | 0,9944 | 0,0142 | 0,9856 | 0,9876 |
| Тестовый | 0,9990 | 0,0158 | 0,9911 | 0,9826 |

Сопоставимые значения на обучающем, валидационном и тестовом наборе данных подтверждают высокое качество обученной модели. Искусственная нейронная сеть не просто запоминает данные, а обладает способностью корректно сегментировать водные объекты на изображениях за пределами обучающей и валидационной выборки.

На рисунке 4 представлено изменение ключевых метрик в процессе обучения нейросети

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN},$$

$$precision = \frac{TP}{TP + FP},$$

$$recall = \frac{TP}{TP + FN},$$

$$F1-score = \frac{2 \cdot precision \cdot recall}{precision + recall},$$

где TP – количество наблюдений, правильно классифицированных как водные объекты; TN – количество наблюдений, правильно классифицированных как не водные объекты; FP – количество наблюдений, ошибочно классифицированных как водные объекты; FN – количество наблюдений, ошибочно классифицированных как не водные объекты.

Результат работы «Lanky U-Net» на тестовом изображении, сравнение с результатом работы «U-Net» и эталонная маска приведены на рисунке 5.

Визуальный анализ полученных масок подтверждает эффективность обученной на собственном наборе данных модели «Lanky U-Net». Кроме того, на одном и том же изображении при запуске модели «Lanky U-Net» маска воды была получена за 12 секунд, что в 2,5 раза быстрее, чем при запуске модели «U-Net».

Для обнаружения наводнений используется маска постоянной воды поверхности земли, выгруженная с сервиса [16]. Метаданные маски, полученной в результате работы нейросети, сопоставляются с координатами маски постоянной воды, в результате чего происходит вычитание последней из первой. Полученная таким образом новая маска соответствует зонам наводнения на рассматриваемом участке. Для удобства работы формируется цветная маска,

где синий цвет обозначает постоянную воду, а красный – наводнение. На рисунке 6 представлен результат автоматического обнаружения наводнения, произошедшего 30.04.2024 в городе Балаково Саратовской области.

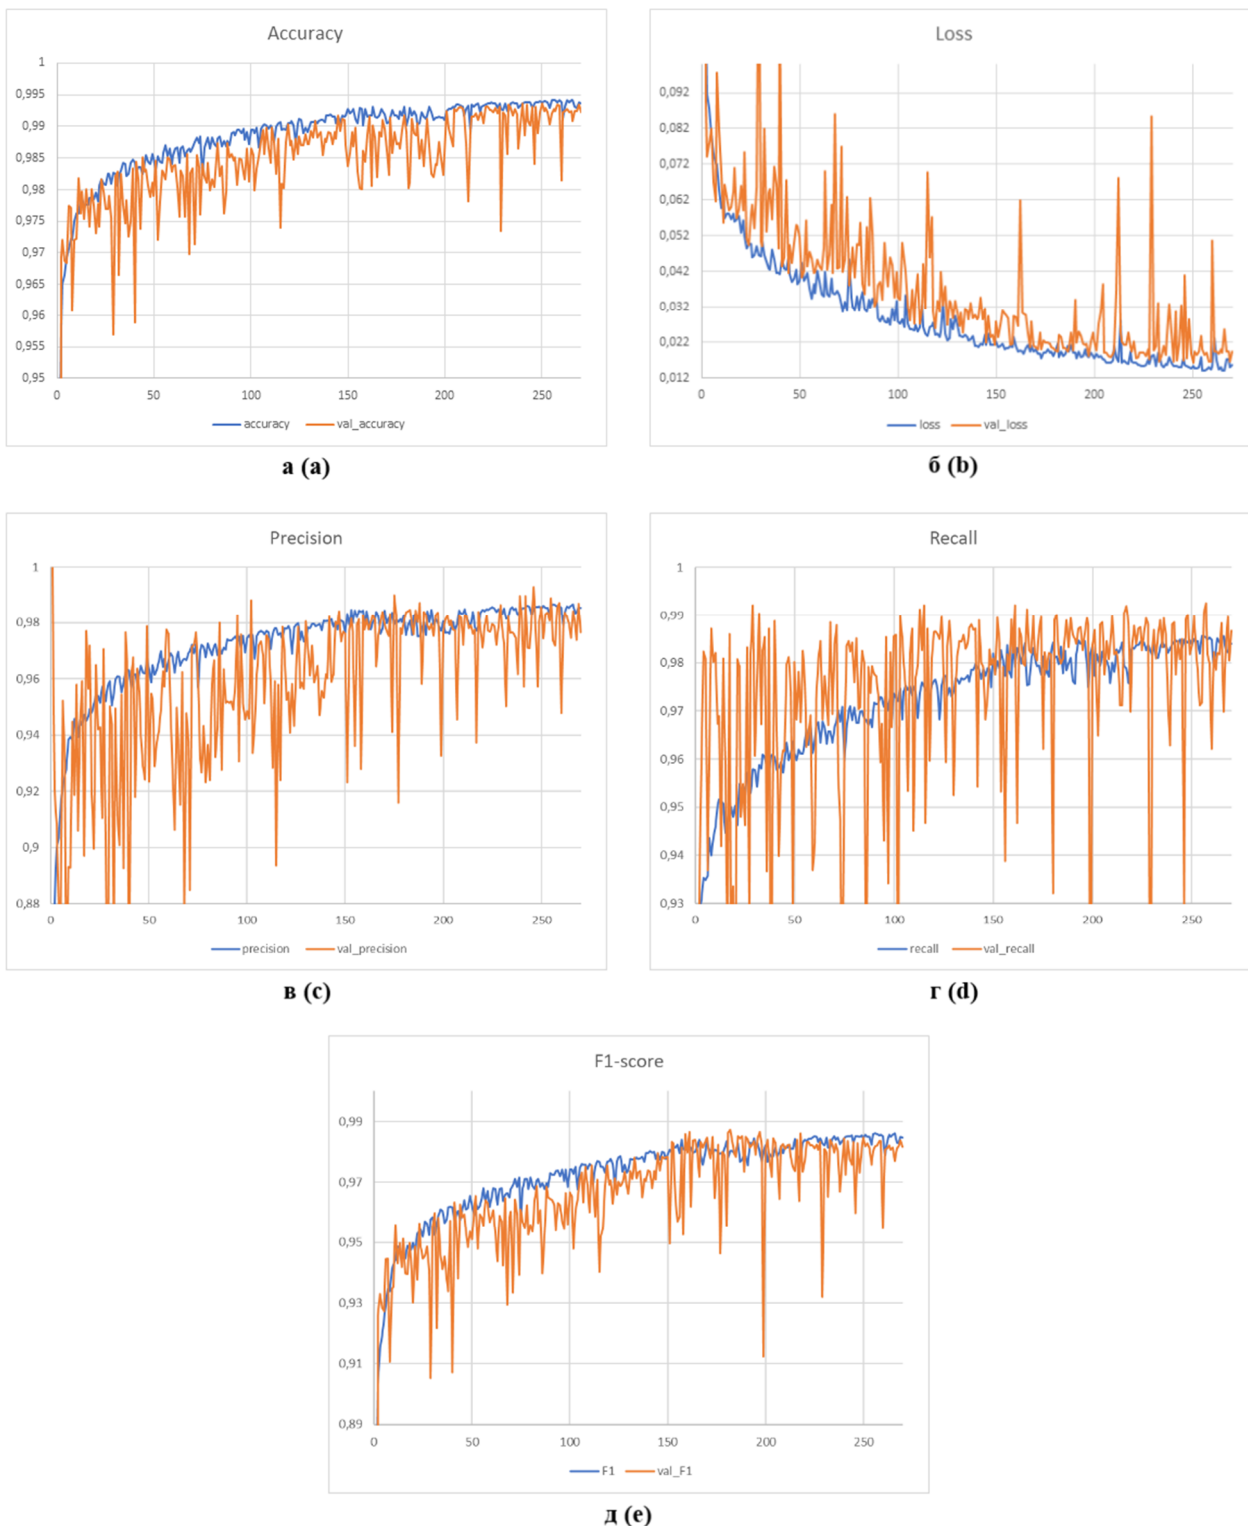


Рисунок 4 – Графики изменения показателей в процессе обучения:

а – accuracy; б – loss; в – precision; г – recall; д – F1-score

Figure 4 – Changes in metrics during learning:

а – accuracy; б – loss; в – precision; д – recall; е – F1-score




Рисунок 5 – Сравнение результатов работы нейросетей
Figure 5 – Comparison of neural network performance




Рисунок 6 – Автоматическое обнаружение наводнения
Figure 6 – Automatic flood detection

Заключение

Применение нейросетевых подходов при анализе спутниковых данных позволяет получать верные и надёжные сведения, минимизируя человеческий фактор. В результате проведённого исследования разработан инструмент для автоматической сегментации наводнений.

На основе мультиспектральных данных получена репрезентативная выборка, охватывающая разнообразные сюжеты спутниковой съёмки.

Итоги работы могут быть использованы как автоматический инструмент для научных исследований гидрографической сети, а также для выявления зон затопления при мониторинге чрезвычайных ситуаций. Сформированный в ходе работы набор данных может служить отправной точкой для других исследований, в том числе в смежных областях. Кроме того, результаты исследования планируется использовать в геопортале спутниковых снимков [17].

В будущем планируются работы, направленные на адаптацию модели для работы с данными других спутников, в том числе отечественных, а также расширение выборки для улучшения эффективности модели при работе в других регионах.

Библиографический список

1. **Антонова А.А., Алексеенко Я.В., Каргашев В.И., Фахми Ш.С.** Подход к построению системы обработки открытых данных дистанционного зондирования земли для мониторинга наводнений с использованием технологий больших данных // Космическая техника и технологии. 2025. № 1. С. 116-141.
2. **McFeeters.** The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features // INT. J. REMOTE SENSING. 1996. Т. 17. № 7. С. 1425-1432.
3. **Zhou et al.** A New Index Model NDVI-MNDWI for Water Object Extraction in Hybrid Area // Geoinformatics in Resource Management and Sustainable Ecosystem. 2015. С. 513-519.
4. **Gudina et al.** Automated Water Extraction Index: A New Technique for Surface Water Mapping Using Landsat Imagery // Remote Sensing of Environment. 2014. Т. 140. С. 23-35.
5. **Otsu N.** A Threshold Selection Method from Gray-Level Histograms // IEEE Transactions on Systems, Man, and Cybernetics. 1979. Т. 9. С. 62-66.
6. **Maurício C.R. Cordeiro, Jean-Michel Martinez, Santiago Peña-Luque.** Automatic water detection from multidimensional hierarchical clustering for Sentinel-2 images and a comparison with Level 2A processors // Remote Sensing of Environment. 2021. Т. 253. С. 1-15.
7. **Donglian Sun, Yunyue Yu, Rui Zhang, Sanmei Li, and Mitchell D. Goldberg.** Towards Operational Automatic Flood Detection Using EOS/MODIS Data // Photogrammetric Engineering & Remote Sensing. 2012. С. 637-646.
8. **Portales-Julia E., Mateo-Garcia G., Purcell C., Gomez-Chova L.** Global flood extent segmentation in optical satellite images // Sci Rep. 2023. № 13. С. 1-14.
9. **Москвитин А.Э., Ушенкин В.А., Ларюков С.А.** Алгоритм и программный комплекс высокоскоростной нейросетевой сегментации облачности на панхроматических изображениях от космических аппаратов «Ресурс-П» // Цифровая обработка сигналов. 2023. № 3. С. 8-18.
10. **Goodfellow et al.** Deep Learning // MIT Press. 2016. С. 174-175.
11. Sentinel Hub [Электронный ресурс] // URL: <https://www.sentinel-hub.com/> (дата обращения: 05.09.2025).
12. Amazon Web Services [Электронный ресурс] // URL: <https://aws.amazon.com/> (дата обращения: 12.09.2025).
13. **Kingma D.P., Ba J.L.** Adam: a method for stochastic optimization // ICLR. 2015. С. 1-15.
14. Google Colab [Электронный ресурс] // URL: <https://colab.research.google.com/> (дата обращения: 03.11.2025).
15. Описание формата сжатия Deflate [Электронный ресурс] // URL: https://compression.ru/download/articles/lz/mihalchik_deflate_decoding.html (дата обращения: 15.07.2025).
16. Joint Research Centre – Global Surface Water [Электронный ресурс] // URL: <https://global-surface-water.appspot.com/download> (дата обращения: 15.12.2025).
17. **Кузнецов А.Е., Кочергин А.М., Ларюков С.А.** Современные подходы по организации обработки и обеспечения потребителей данными ДЗЗ высокого разрешения // Цифровая обработка сигналов. 2020. № 3. С. 3-8.

UDC 004.932

NEURAL NETWORK FLOOD DETECTION TECHNOLOGIES BASED ON DATA FROM SENTINEL-2 SPACECRAFT

A. S. Vendin, Student, R&D Technician at Research Institute «Photon», RSREU, Ryazan, Russia;
orcid.org/0009-0005-1379-5580, e-mail: vendin0505@mail.ru

S. A. Laryukov, Post-graduate student at RSREU, Junior Researcher at Research Institute «Photon» RSREU, Ryazan, Russia;
orcid.org/0009-0009-9082-1454, e-mail: foton@rsreu.ru

The problem of flood segmentation and water body detection based on satellite imagery from Sentinel-2 mission is considered. The aim of this work is to develop automated software tools that allow for automatic and accurate monitoring of water bodies using remote sensing data and artificial intelligence methods. The paper analyzes known approaches to solving this problem and identifies their shortcomings, which explains the relevance of new research in this area. Due to limited applicability of existing methods, as well as low quality of labeling in public datasets, a neural network based on «Lanky U-Net» architecture and trained on manually annotated dataset is proposed. As a result of the research, the following objectives were addressed: preparation and labeling of multispectral images obtained from Sentinel-2 satellites showing flooded areas in Russian regions; training a model for water body detection; evaluating model performance using accuracy, precision, recall, and loss values; and flood detection using a static water body mask. Numerical indicators of segmentation quality and experimental results are presented, demonstrating the effectiveness of the proposed approach.

Keywords: convolutional neural networks, machine learning, water bodies segmentation, automatic flood detection, Earth remote sensing data processing.

DOI: 10.21667/1995-4565-2026-95-192-201

References

1. Antonova A.A., Alekseenko Ja.V., Kartashev V.I., Fahmi Sh.S. Podhod k postroeniju sistemy obrabotki otkrytyh dannyh distancionnogo zondirovaniya zemli dlja monitoringa navodnenij s ispol'zovaniem tehnologij bol'shijh dannyh. *Kosmicheskaja tehnika i tehnologii*. 2025, no. 1, pp. 116-141. (in Russian).
2. McFeeters. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *INT. J. REMOTE SENSING*. 1996, vol. 17, no. 7, pp. 1425-1432.
3. Zhou et al. A New Index Model NDVI-MNDWI for Water Object Extraction in Hybrid Area. *Geo-Informatics in Resource Management and Sustainable Ecosystem*. 2015, pp. 513-519.
4. Gudina et al. Automated Water Extraction Index: A New Technique for Surface Water Mapping Using Landsat Imagery. *Remote Sensing of Environment*. 2014, vol. 140, pp. 23-35.
5. Otsu N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*. 1979, vol. 9, pp. 62-66.
6. Mauricio C.R. Cordeiro, Jean-Michel Martinez, Santiago Peña-Luque. Automatic water detection from multidimensional hierarchical clustering for Sentinel-2 images and a comparison with Level 2A processors. *Remote Sensing of Environment*. 2021, vol. 253, pp. 1-15.
7. Donglian Sun, Yunyue Yu, Rui Zhang, Sanmei Li, and Mitchell D. Goldberg. Towards Operational Automatic Flood Detection Using EOS/MODIS Data. *Photogrammetric Engineering & Remote Sensing*. 2012, pp. 637-646.
8. Portales-Julia E., Mateo-Garcia G., Purcell C., Gomez-Chova L. Global flood extent segmentation in optical satellite images. *Sci Rep*. 2023, no. 13, pp. 1-14.
9. Moskvitin A.Je., Ushenkin V.A., Laryukov S.A. Algoritm i programmnyj kompleks vysokorostnoj nejrosetevoj segmentacii oblachnosti na panhromaticeskijh izobrazhenijah ot kosmicheskijh apparatov «Resurs-P». *Cifrovaja obrabotka signalov*. 2023, no. 3, pp. 8-18. (in Russian).
10. Goodfellow et al. Deep Learning. MIT Press. 2016, pp. 174-175.
11. Sentinel Hub [Electronic resource]. URL: <https://www.sentinel-hub.com/> (Date of request: 05.09.2025).

12. *Amazon Web Services* [Electronic resource]. URL: <https://aws.amazon.com/> (Date of request: 12.09.2025).
13. **Kingma D.P., Ba J.L.** Adam: a method for stochastic optimization. *ICLR*. 2015, pp. 1-15.
14. *Google Colab* [Electronic resource]. URL: <https://colab.research.google.com/> (Date of request: 03.11.2025).
15. *Opisanie formata szhatija Deflate* [Electronic resource]. URL: https://compression.ru/download/articles/lz/mihalchik_deflate_decoding.html (Date of request: 15.07.2025).
16. *Joint Research Centre – Global Surface Water* [Electronic resource]. URL: <https://global-surface-water.appspot.com/download> (Date of request: 15.12.2025).
17. **Kuznetsov A.E., Kochergin A.M., Laryukov S.A.** Sovremennye podhody po organizacii obrabotki i obespechenija potrebitelej dannymi DZZ vysokogo razreshenija. *Cifrovaja obrabotka signalov*. 2020, no. 3, pp. 3-8. (in Russian).