

ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБРАБОТКИ СПУТНИКОВЫХ ДАННЫХ В ЗАДАЧЕ МОНИТОРИНГА ПАВОДКОВОЙ ОБСТАНОВКИ В БАССЕЙНЕ РЕКИ АМУР

М.О. Кучма¹, А.Н. Давиденко¹, А.К. Малков¹, А.В. Бородицкая¹

¹*Дальневосточный Центр ФГБУ "Научно-исследовательский центр космической гидрометеорологии "Планета", Хабаровск, m.kuchma@dvrspod.ru*

Аннотация: *в работе представлено описание нейросетевого алгоритма для детектирования речных разливов в бассейне реки Амур по данным метеорологических космических аппаратов. Алгоритм основан на сверточной нейронной сети типа U-net, которая была адаптирована эмпирическим методом под решаемую задачу. Анализ проведенной оценки точности показал, что разработанные алгоритмы позволяют детектировать речные разливы с достаточной точностью.*

Ключевые слова: *наводнение, Амур, нейронные сети, дистанционное зондирование Земли, Sentinel, Landsat, Канопус-В, индексные изображения*

Актуальность. Мониторинг паводковой обстановки в бассейне реки Амур является актуальной задачей для Дальневосточного региона России. Причина этого заключается в том, что речная сеть региона достаточно густая и подвержена частым разливам. Поскольку наземная наблюдательная сеть на этой территории распределена крайне неравномерно, основным источником информации о текущем состоянии водных объектов являются данные дистанционного зондирования Земли (ДЗЗ), которые позволяют проводить одномоментный анализ большой территории.

Обсуждение результатов. Для проведения качественного мониторинга паводковой обстановки по данным ДЗЗ принято использовать карты речных разливов, на которых дешифрируются как основное русло реки, так и затопленные участки пойм рек. Пример таких карт, выпускаемых в Дальневосточном центре (ДЦ) НИЦ «Планета», представлен на рис. 1.

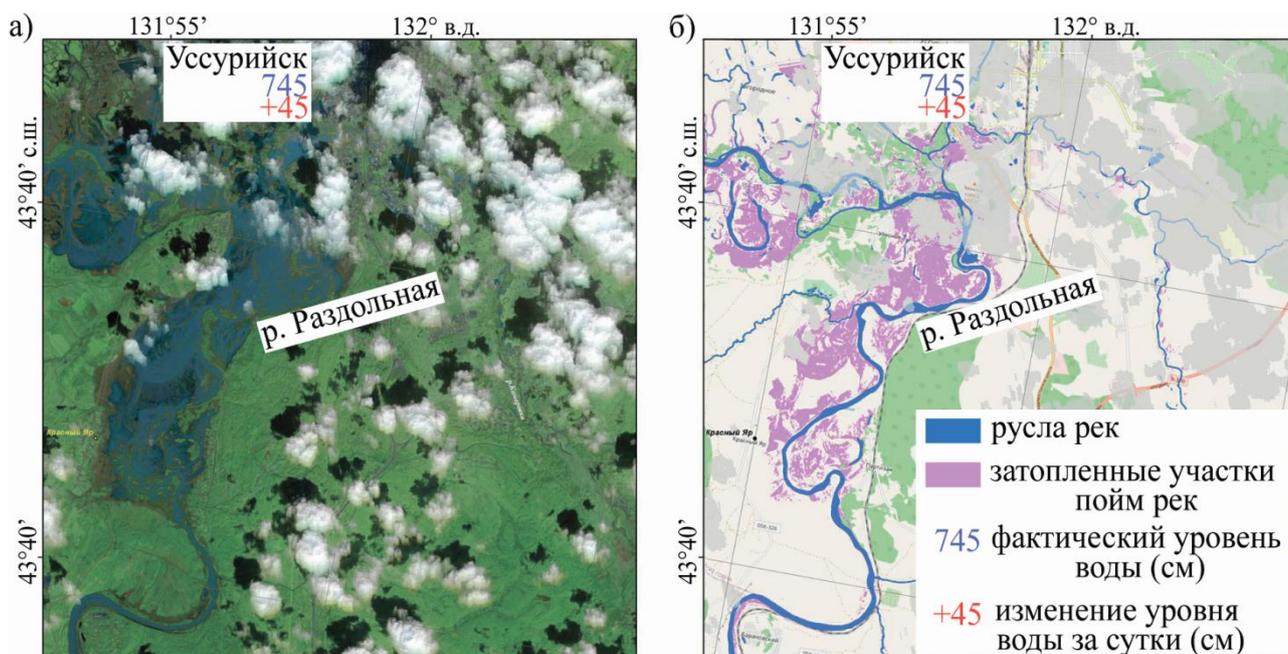


Рис. 1. Гидрологическая обстановка на реке Раздольная 26 августа 2023 г. по данным космического аппарата Канопус-В №3: а) синтезированное изображение, синтез в «естественных» цветах; б) совмещение затопленных площадей, выделенных на спутниковом изображении, с картой OpenStreetMap.

До недавнего времени подобные карты рассчитывались путем ручного, визуального и интерактивного дешифрирования, так как условия съемки, особенности водного состава и сложный рельеф в значительной степени осложняют создание автоматических алгоритмов.

Для решения подобных задач в мировой практике распространено использование различных алгоритмов и методов. Самыми распространенными являются алгоритмы пиксельного анализа данных [1-2]. К алгоритмам пиксельного анализа относятся те, которые используют пороговые значения какого-либо параметра для определения типов объектов по спутниковым данным, или по-другому – спектральные алгоритмы.

В последние годы для мониторинга наводнений применялись методы машинного обучения, такие как опорные вектора и случайный лес [3]. Основываясь на анализе перечисленной информации, а также на основе российского опыта в области ДЗЗ [5-6], можно сделать вывод о том, что в последнее время ведутся активные работы по исследованию и разработке алгоритмов глубокого обучения, в частности сверточных нейронных сетей (СНС). Они могут успешно применяться при решении различного рода тематических задач. В связи с этим для решения обозначенных задач в ДЦ НИЦ «Планета» применена методика контролируемого обучения сверточной СНС.

Использование выбранной методики базируется, в первую очередь, на процессе обучения, основанном на итерационном подборе весовых коэффициентов с целью минимизации целевой функции. После завершения этого процесса весовые коэффициенты фиксируются, и уже обученная нейронная сеть используется для непосредственных расчетов. Для того чтобы начать этот процесс, необходимо создать обучающую выборку.

Создание обучающей выборки является трудоемким процессом, поскольку зачастую эталонных данных по интересующей территории в свободном доступе нет. В настоящей работе для получения примеров разливов и эталонной информации, были привлечены опытные специалисты-дешифровщики ДЦ НИЦ «Планета». Для выборки использовались данные спутниковых приборов, пространственное разрешение которых не превышает 30 метров на пиксель. Под такие требования подходят данные приборов MSI, OLI и MCC, установленных на зарубежных космических аппаратах (КА) Sentinel-2, Landsat-8 и российских КА серии Канопус-В соответственно. Таким образом, была набрана обучающая выборка для сцен 250x250 пикселей в количестве 15480, 6320 и 344 текстур для приборов MSI, OLI и MCC соответственно. Используемые для обучения текстуры были случайным образом поделены на подвыборки: 70% для обучения, 20% для проверки и 10% для тестирования.

Для обучения СНС по данным прибора MSI за основу была взята модель U-net [7], которая была доработана для получения оптимального результата при решении задачи выделения разливов. Модернизированная архитектура U-net (рис. 2) отличается от классической тем, что в неё добавлены два дополнительных понижающих дискретизацию слоя и слои пакетной нормализации после каждой функции активации.

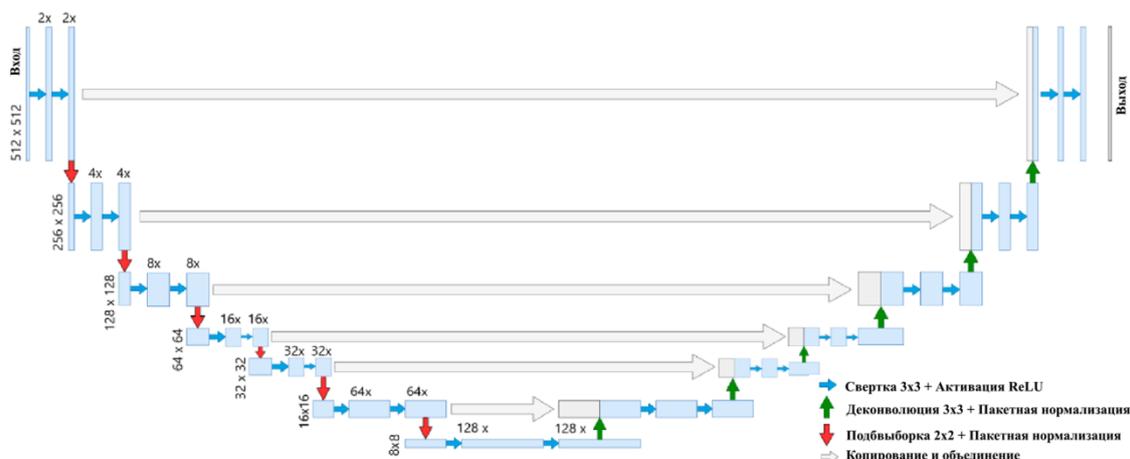


Рис. 2. Модернизированная нейронная сеть типа U-net для детектирования речных разливов

Эмпирическим методом были определены оптимальный размер текстур 512x512 пикселей и набор входных параметров: коэффициент спектральной яркости (КСЯ) каналов № 2, № 3 (Green), № 4 (Red) и № 8 (NIR) прибора MSI; отношения КСЯ каналов – № 2/ № 4, № 4/ № 3; индексы Normalized Difference Water Index (NDWI), Modified Soil-Adjusted Vegetation Index (MSAVI), Normalized Difference Vegetation Index (NDVI), комбинация индексов Enhanced Vegetation Index (EVI), NDVI и NDWI, а именно (NDVI+EVI)/2-NDWI:

$$NDWI = \frac{Green - NIR}{Green + NIR},$$

$$NDVI = \frac{NIR - Red}{NIR + Red},$$

$$MSAVI = \frac{1}{2} \cdot \left(2 \cdot (NIR + 1) - \sqrt{2 \cdot (2 \cdot NIR + 1) - 8 \cdot (NIR - Red)} \right),$$

$$EVI = 2,5 \cdot \frac{NIR - Red}{NIR + 6 \cdot Red - 7,5 \cdot Blue + 1},$$

где: Blue – канал № 2, Green – канал № 3, Red – канал № 4, NIR – канал № 8 прибора MSI соответственно.

Обучение заняло 35 эпох, при этом точность работы алгоритма на тестовой выборке составила 90,78%.

Для данных OLI использовалась полученная ранее архитектура СНС (рис. 2) и размер текстур, при этом анализировались каналы № 2-7, а также индексы Modified Normalized Difference Water Index (MNDWI), Water Ratio Index (WRI) и Automated Water Extraction Index (AWEI):

$$MNDWI = \frac{Green - SWIR2}{Green + SWIR2},$$

$$WRI = \frac{Green + Red}{NIR + SWIR2},$$

$$AWEI = 4 \cdot (Green - SWIR2) - (0,25 \cdot NIR + 2,75 \cdot SWIR1),$$

где: Blue – канал № 2, Green – канал № 3, Red – канал № 4, NIR – канал № 5, SWIR1 – канал № 6, SWIR2 – канал № 7 прибора OLI соответственно.

В результате проведенных экспериментов, как и в случае с MSI, выбиралась та комбинация параметров, которая показала наибольшую точность: значения КСЯ каналов № 4, № 5, № 6 и № 9 прибора OLI; индексы NDWI, EVI, WRI, AWEI, NDVI и комбинация индексов (NDVI+EVI)/2-NDWI. Обучение заняло 127 эпох, а точность – 93,54%.

Информация каналов МСС № 1 (Blue), № 2 (Green), № 3(Red), № 4 (NIR) была преобразована в физические величины, после чего было проведено обучение СНС (рис. 2) с размером текстур 512x512x пикселей. При этом в качестве входных параметров тестировались, помимо NDWI, MSAVI, NDVI и EVI, индексы Chlorophyll Absorption Ratio Index (CARI), Adjusted Transformed Soil-Adjusted Vegetation Index (ATSAVI), а также отношение каналов № 2 и № 4 (Datt1) [8], и № 1, № 3 и № 4 (Datt6) [8]:

$$ATSAVI = 1,22 \cdot \frac{(NIR - 1,22 \cdot Red - 0,03)}{1,22 \cdot NIR + Red - 1,22 \cdot 0,3 + 0,08 * (1 + 1,4884)},$$

$$CARI = \frac{Red}{Green} \cdot \sqrt{\frac{\left(\frac{Red - Blue}{150} \cdot 670 + Green + (Blue - 550 \cdot \frac{Red - Blue}{150})^2\right)}{\frac{Red - Blue}{150} + 1}},$$

$$Datt1 = \frac{NIR - Red}{NIR - Green},$$

$$Datt6 = \frac{NIR}{Blue \cdot Red}.$$

где: Blue – канал № 1, Green – канал № 2, Red – канал № 3, NIR – канал № 4 прибора МСС соответственно.

В результате проведенных экспериментов была определена следующая комбинация параметров, обеспечивающих лучшую точность: каналы № 1, № 2, № 3, № 4 прибора МСС, а также индексы ATSAVI, CARI, NDWI, Datt1, Datt6. Обучение заняло 953 эпохи, значение функции потерь составило 0,12, а точность – 91,2%.

После завершения процесса обучения проводилось сравнение с эталонной маской на данных, которые не принимали участие при обучении и тестировании, чтобы получить независимые результаты валидации. Результаты показаны на рис. 3. Проведенный визуальный анализ полученных карт в большинстве случаев выявил их соответствие эталонным картам. В некоторых ситуациях наблюдаются проблемы с тенями от облачности, которые классифицируются как вода.

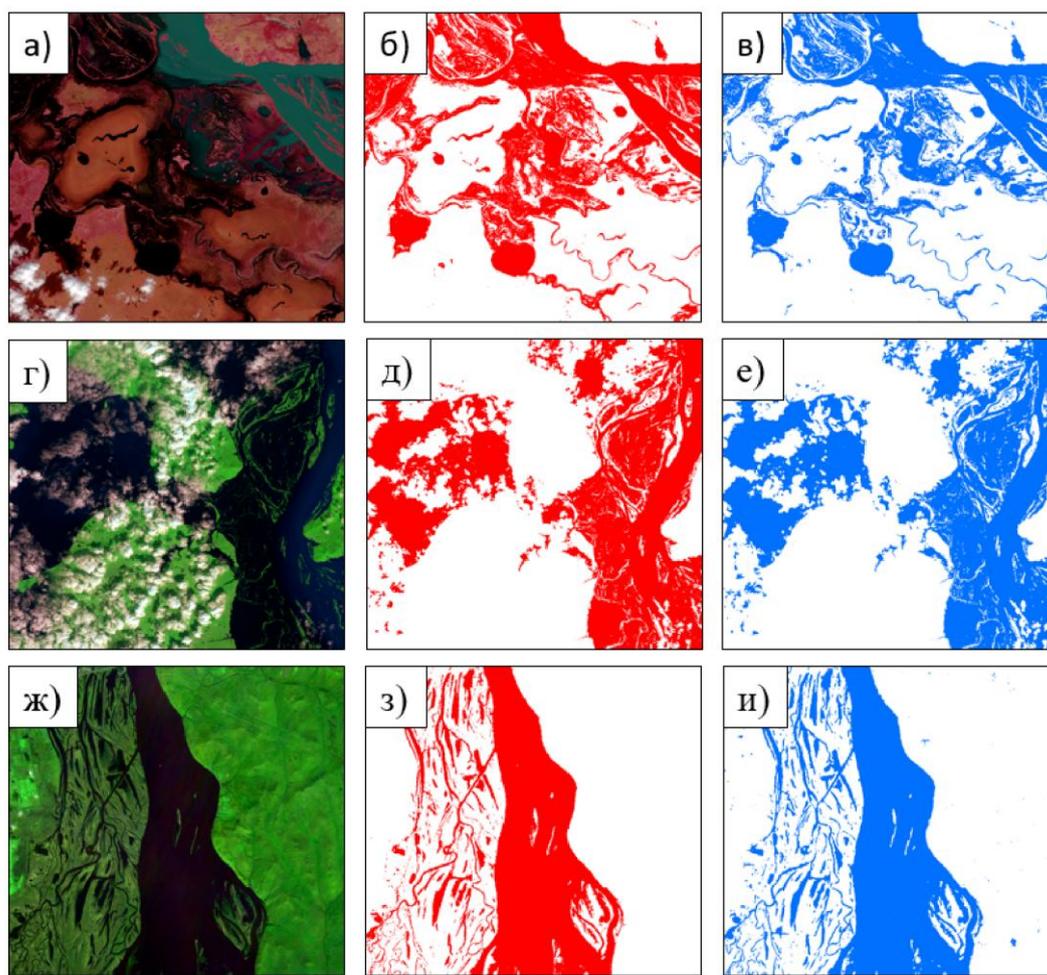


Рис. 3. Результаты классификации водной поверхности: а) мультиспектральное изображение MSI; б) эталонная векторная карта; в) результат работы разработанного алгоритма; г) мультиспектральное изображение OLI; д) эталонная векторная карта; е) результат работы разработанного алгоритма; ж) мультиспектральное изображение MSS; з) эталонная векторная карта; и) результат работы разработанного алгоритма.

Заключение. Таким образом, был получен нейросетевой алгоритм, который позволяет производить детектирование речного разлива в бассейне реки Амур по данным КА Sentinel-2, Landsat-8 и КА серии Канопус-В. На основе полученных алгоритмов для каждого КА были разработаны соответствующие программы на языке программирования Python. Полученные программы работают автоматически в оперативном режиме и интегрированы в технологическую цепочку обработки и подготовки спутниковых данных для геоинформационных систем (ГИС) мониторинга и поддержки принятия решений ГИС «МЕТЕО ДВ» и «ГИС Амур». Дальнейшие усовершенствования алгоритма направлены на устранение текущих недостатков.

Библиографический список

1. Рылов С. А., Новгородцева О. Г., Пестунов И. А. и др. Технология обработки данных с космических аппаратов «Канопус-В», «Ресурс-П» и Метеор-М для мониторинга и картографирования паводковой ситуации // Региональные проблемы дистанционного зондирования Земли: материалы II международной научной конференции // Сиб. федер. ун-т, Ин-т космич. и информ. технологий; науч. ред. Е. А. Ваганов; отв. ред. М. В. Носков. – 2015. – 367 с.
2. Li M., Zhang T., Tu Y. et al. Monitoring Post-Flood Recovery of Croplands Using the Integrated Sentinel-1/2 Imagery in the Yangtze-Huai River Basin // *Remote Sens.* – 2022. – Vol. 14. – P. 690.
3. Tanim A. H. et al. Flood Detection in Urban Areas Using Satellite Imagery and Machine Learning // *Water. MDPI AG.* – 2022. – Vol. 14, Issue 7. – Article 1140.
4. Kim J., Kim H., Jeon H. et al. Synergistic Use of Geospatial Data for Water Body Extraction from Sentinel-1 Images for Operational Flood Monitoring across Southeast Asia Using Deep Neural Networks // *Remote Sens.* – 2021. – Vol. 13. – Article 4759.
5. Andreev A. I., Shamilova Y. A., Kholodov E. I. Using Convolutional Neural Networks for Cloud Detection from Meteor-M No. 2 MSU-MR Data // *Russian Meteorology and Hydrology.* – 2019. – Vol. 44, Iss. 7. – pp. 459–466.
6. Kramareva L. S., Andreev A. I., Simonenko E. V. et al. The use of a convolutional neural network for detecting snow according to the data of the multichannel satellite device of meteor-M No.2 spacecraft // *Procedia Computer Science: Proceedings of the 13th International Symposium "Intelligent Systems", INTELS 2018, St. Petersburg, 22–24 october 2018.* – St. Petersburg: Elsevier B.V. – 2019. – pp. 368–375.
7. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // *Proc. Int. Conf. Med. Image Comput. Comput.-Assist. Intervent.* – 2015. – pp. 234–241
8. Russell Main, Moses Azong Cho, Renaud Mathieu, Martha M. O’Kennedy, Abel Ramoelo, Susan Koch. An investigation into robust spectral indices for leaf chlorophyll estimation // *ISPRS Journal of Photogrammetry and Remote Sensing.* – 2011. – Vol. 66, Iss. 6. – pp. 751–761.

**THE USE OF MACHINE LEARNING METHODS FOR PROCESSING
SATELLITE DATA IN THE PROBLEM OF FLOOD MONITORING
CONDITIONS IN THE AMUR RIVER BASIN**

M.O. Kuchma, A.N. Davidenko, A.K. Malkov, A.V. Boroditskaya
Far-Eastern Center of the Federal State Budgetary Institution «State Research Center
of Space Hydrometeorology «Planeta», Khabarovsk, m.kuchma@dvrcpod.ru

Summary: the paper presents a description of a neural network algorithm for detecting river floods in the Amur River basin using data from meteorological satellites. The algorithm is based on a convolutional neural network of the U-net type, which was adapted empirically to the problem being solved. An analysis of the accuracy assessment showed that the developed algorithms make it possible to detect river floods with sufficient accuracy.

Keywords: river flood, Amur, neural networks, remote sensing, Sentinel, Landsat, Kanopus-V, index images