

Научная статья
УДК 502/ 504; 528.88
DOI: 10.21209/2227-9245-2024-30-3-27-37

Геоэкологическое картирование селитебных территорий Забайкальского края с использованием свёрточной нейронной сети

Денис Владимирович Кочев

Забайкальский государственный университет, г. Чита, Россия
denis.ko4ev@yandex.ru

Информация о статье

Поступила в редакцию
28.06.2024

Одобрена после
рецензирования 19.07.2024

Принята к публикации
06.08.2024

Ключевые слова:

паводкоопасные территории, наводнения, дешифрирование, дистанционное зондирование Земли, нейронные сети, машинное обучение, программа для электронной вычислительной машины, Python, ущерб, картирование

Наводнения представляют серьёзную угрозу для экономики и населения, однако их опасность зачастую недооценивается. В результате этого потенциально опасные участки хозяйственных территорий подвергаются интенсивной застройке, что приводит к ущербу при их затоплении. Использование современных методов дистанционного зондирования Земли в сочетании с алгоритмами глубокого обучения позволяет значительно повысить эффективность и точность картирования данных территорий, а также предоставляет возможность эффективно ими управлять, оптимизируя процессы планирования и развития территорий, снижая ущерб при затоплении. Объект исследования – паводкоопасные территории населённых пунктов Забайкальского края. Цель исследования – усовершенствование геоэкологического картирования хозяйственного использования селитебных территорий Забайкальского края, подверженных наводнениям, в межпаводковый период. Задачи исследования: обработка снимков; визуализация объектов, принадлежащих к разным классам хозяйственного использования; анализ и оценка изменений в пределах опасных территорий; проверка результатов, полученных с использованием свёрточной нейронной сети; разработка программного продукта, позволяющего информировать заинтересованных лиц о наличии опасных территорий. В работе использованы методы исследований в области дистанционного зондирования Земли и обработки картографической информации. Получены данные дистанционного зондирования высокого разрешения, свободно распространяемые сервисами Google Earth, и данные с беспилотных летательных аппаратов. Данные представлены в растровом формате и имеют координатную привязку. Обработку данных осуществляли с помощью свёрточной нейронной сети U-Net. Выполнены обработка снимков с использованием нейросети и визуализация объектов, принадлежащих к разным классам хозяйственного использования территорий. Произведены ретроспективный анализ и оценка изменений застройки в опасных территориях. Данные показывают активное индивидуальное строительство в опасной зоне. Осуществлена проверка адекватности результатов, полученных с использованием свёрточной нейронной сети. Разработан программный продукт, позволяющий определить наличие опасных территорий в пределах населённых пунктов, что позволяет значительно повысить эффективность и точность картирования хозяйственной деятельности в населённых пунктах.

Благодарности: исследование проведено при финансовой поддержке Фонда содействия развитию малых форм предприятий в научно-технической сфере, грант № 17803ГУ/2022.

Original article

Geocological Mapping of Urbanized Territories of the Transbaikal Territory Using a Convolutional Neural Network

Denis V. Kochev

Transbaikal State University, Chita, Russia
denis.ko4ev@yandex.ru

Information about the article

Received 28 June 2024

Approved after review
19 July 2024

Accepted for publication
6 August 2024

Floods pose a serious threat to economies and communities, but their danger is often underestimated. As a result, potentially dangerous areas of economic territories are subject to intensive development, which leads to damage when they are flooded. The use of modern methods of remote sensing of the Earth in combination with deep learning algorithms can significantly increase the efficiency and accuracy of mapping these territories and makes it possible to effectively manage them, optimizing the pro-

cesses of planning and development of territories, reducing damage due to flooding. The object of the study is flood-prone areas of settlements in the Transbaikalian Territory. The goal of the study is to improve geoeological mapping of the economic use of residential areas of the Transbaikalian Territory that are prone to floods during the inter-flood period. The research objectives are as follows: image processing; visualization of objects belonging to different classes of economic use; analysis and assessment of changes within hazardous areas; checking the results obtained using a convolutional neural network; development of a software product that allows you to inform interested parties about the presence of dangerous territories. The methodology and methods are presented by research methods in the field of remote sensing of the Earth and processing of cartographic information. High-resolution remote sensing data, freely distributed by Google Earth services, and data from UAVs were obtained. The data is given in raster format and has a coordinate reference. Data processing has been carried out using the U-Net convolutional neural network and image processing by using a neural network and visualization of objects belonging to different classes of economic use of territories. A retrospective analysis and assessment of development changes in hazardous areas has also been performed. The data obtained show active individual construction in the danger zone. The adequacy of the results obtained using a convolutional neural network was checked. A software product has been developed to determine the presence of hazardous areas within populated areas, which can significantly increase the efficiency and accuracy of mapping economic activities in populated areas.

Keywords:

flood-prone areas, floods, decryption, remote sensing of the Earth, neural networks, machine learning, computer program, Python, damage, mapping

Acknowledgement: *the study was conducted with the financial support of the Foundation for the Promotion of Small Enterprises in the Scientific and Technical field, grant No. 17803GU/2022*

Введение. Территория Забайкальского края по своим природным условиям классифицируется как паводкоопасный регион, что подтверждается данными Водной стратегии Российской Федерации. Сложные географические условия Забайкальского края обуславливают активное использование речных долин для проживания населения, ведения сельскохозяйственного и промышленного производства, а также для создания транспортных коммуникаций [7]. В поймах р. Ингода, Чита, Онон, Шилка, Аргунь расположена значительная часть городов и сёл региона. Следовательно, во время наводнений под угрозой затопления оказывается не менее 130 населённых пунктов [6]. Процесс картирования затруднителен из-за временных и трудовых затрат для человека. Глубокое обучение, благодаря своим возможностям в области мультисенсорной и разновременной классификации, становится центральным методом в решении проблем картирования по данным дистанционного зондирования [13].

Объект исследования – паводкоопасные территории населённых пунктов Забайкальского края.

Предмет исследования – геоэкологическое картирование территорий населённых пунктов с помощью свёрточной нейронной сети.

Цель исследования – усовершенствование геоэкологического картирования хозяйственного использования селитебных тер-

риторий Забайкальского края, подверженных наводнениям, в межпаводковый период.

Задачи исследования: обработка снимков с использованием свёрточной нейронной сети; визуализация объектов, принадлежащих к разным классам хозяйственного использования территорий; анализ и оценка изменений в пределах опасных территорий; проверка адекватности результатов, полученных с использованием свёрточной нейронной сети; разработка программного продукта, позволяющего информировать заинтересованных лиц о наличии опасных территорий в пределах крупных населённых пунктов.

Материалы и методы исследования. Наблюдение за уровнем хозяйственного освоения территорий, подверженных паводкам, позволит эффективно управлять их использованием, способствовать восстановлению, обеспечивать безопасное планирование и развитие их экономического потенциала, а также предоставит возможность оценить возможные убытки для застройки и других значимых объектов экономики, вызванные паводками и неблагоприятными гидрометеорологическими явлениями. Использован комплексный подход, включающий методы исследований в области дистанционного зондирования Земли и обработки картографической информации. Получены данные дистанционного зондирования высокого разрешения Махаг, Digital Globe, Ikonos, свободно распространяемые сервисами Google Earth. Для анализа использованы сведения беспилотных лета-

тельных аппаратов (далее – БПЛА). Данные представлены в растровом формате GeoTiff и имеют координатную привязку на системе WGS-84. Обработку данных осуществляли с помощью свёрточной нейронной сети U-Net, с энкодером SE-ResNeXt50.

Разработанность темы исследования. Согласно актуальным научным данным, наблюдается значительное увеличение рисков возникновения чрезвычайных ситуаций и размера ущербов от опасных природных явлений гидрометеорологического характера в связи с застройкой опасных территорий. Оперативный мониторинг данных зон возможен благодаря использованию данных дистанционного зондирования Земли. Тем не менее существуют значительные проблемы в анализе этих данных, ввиду их большого объёма и длительной, трудоёмкой, рутинной обработки [4]. Введение методов оперативного мониторинга и анализа данных дистанционного зондирования даёт возможность более эффективно управлять этими зонами, минимизируя ущерб и оптимизируя процессы планирования и развития территорий [12].

Благодаря использованию алгоритмов искусственного интеллекта, в частности технологий глубокого обучения свёрточных нейронных сетей, появляется возможность точной классификации и извлечения структуры исследуемых объектов. Это приближает данный тип анализа к визуальному дешифрированию, что является неоспоримым преимуществом по сравнению с традиционными методами автоматического дешифрирования исследуемых объектов [5].


В работе проведена оценка динамики застройки и хозяйственного освоения паводкоопасных территорий на основе разновременных космических снимков, что позволяет выявить тенденции и изменения за определённые промежутки времени. Адекватность и точность результатов проверяли с использованием метрик оценки качества моделей классификации, таких как матрица ошибок (Confusion matrix) и F-мера, что подтверждает достоверность и надёжность полученных данных.

Результаты исследования и их обсуждение. В настоящее время применение алгоритмов искусственного интеллекта является наиболее распространённой технологией в распознавании различной информации на растровых изображениях. Свёрточные нейросети эффективнее также в задачах анализа больших данных со множеством

признаков и сложной структурой различных математических моделей. Свёрточные нейронные сети (Convolutional Neural Networks – CNN) [1; 2], глубокие сети доверия (Deep Belief Networks – DBN) [12] и рекуррентные нейронные сети (Recurrent Neural Networks – RNN) [10] активно применяются для распознавания речи, компьютерного зрения и обработки естественного языка. Существенный прогресс достигнут в области масштабного распознавания изображений [14; 15; 11], обнаружения объектов [1; 8] и семантической сегментации, главным образом благодаря использованию нейронных сетей. Эффективность применяемых алгоритмов подтверждена работами, включающими классификации различных типов покрытия поверхности Земли, такие как здания и дороги, на основе данных оптического и радиолокационного зондирования [9], что способствовало решению широкого спектра задач дистанционного зондирования [13]. Ранее изложенное позволяет сделать вывод о высокой эффективности и результативности работы нейросетей с растровыми данными, что, в свою очередь, позволяет оценить количественные и качественные показатели застройки в пределах не только опасных зон, но и границ населённых пунктов (рис. 1).

Оценить динамику застраиваемости и хозяйственного освоения территорий можно по двум и более разновременным изображениям, однако «на глаз» качественно и количественно это сделать довольно затруднительно (рис. 2).

Для анализа и оценки изменений на изображениях применяют процесс их дешифрирования. Широко распространено визуальное дешифрирование. Для визуального дешифрирования используется геоинформационная система (например, ArcGIS или QGIS). Визуальное дешифрирование отличается от автоматических методов высокой точностью, однако имеются существенные недостатки с низкой скоростью дешифрирования. Ручная разметка объектов является трудозатратной задачей [3]. Соответственно, разработка и оптимизация свёрточной нейронной сети на архитектуре U-Net являются решением данной задачи благодаря автоматизации процесса дешифрирования. Человек получает дополнительное время для других задач. Ему остаётся только проверить и скорректировать полученный результат, что экономит время и трудовые ресурсы.



г. Нерчинск

Рис. 1. Свёрточная нейронная сеть, которая позволяет выделить и классифицировать различные объекты / **Fig. 1.** Convolutional neural network allows you to identify and classify various objects



Рис. 2. Динамика застройки с. Улёты Забайкальского края за 18-летний период / **Fig. 2.** The development dynamics of the village Uley in the Transbaikalian Territory over an 18-year period

После завершения конфигурации и обучения нейросети подготовлены космоснимки, снимки с БПЛА в различных пространственных разрешениях, которые отправлены на обработку нейросетью. Используются данные полевых исследований с применением БПЛА, а также свободно распространяемые изображения с SASPlanet и GoogleEarthPro. Для анализа отобраны спутниковые снимки пгт Агинское за 2013, 2019 гг. В результате работы нейросети получены растровые изображения с выделенными объектами застройки и объектами хозяйственной деятельности. В

качестве опасной зоны наложен векторный слой зоны с особыми условиями использования территорий (далее – ЗОУИТ) с публичной кадастровой карты. Данная зона практически совпадает с зоной затопления 1 %-й вероятности (рис. 3).

Для сопоставления данных и оценки динамики освоения территорий и прироста застройки в пгт Агинское за 2013–2019 гг. проведён геоинформационный анализ в QGIS и ArcGIS 10.0. Для этого полученные после дешифрирования на свёрточной нейросети растровые изображения подвергали вектори-

зации (конвертировали из растрового формата в векторный), затем с ними производили операцию совмещения разновременных данных, что необходимо для ретроспективного анализа застройки за разные промежутки времени. Для этого использованы данные 2013, 2019 гг. В результате получены данные совмещения различных объектов хозяйственной деятельности за разные годы, наглядно показывающие качественный и количествен-

ный прирост объектов застройки и объектов хозяйственной деятельности.

Полученные данные позволили сделать вывод об активном индивидуальном строительстве в потенциально опасной зоне даже за сравнительно малый период времени (2013–2019 гг.). Количественные показатели площади застройки и земельных участков на территориях, подверженных затоплению в результате наводнений, представлены на рис. 4.

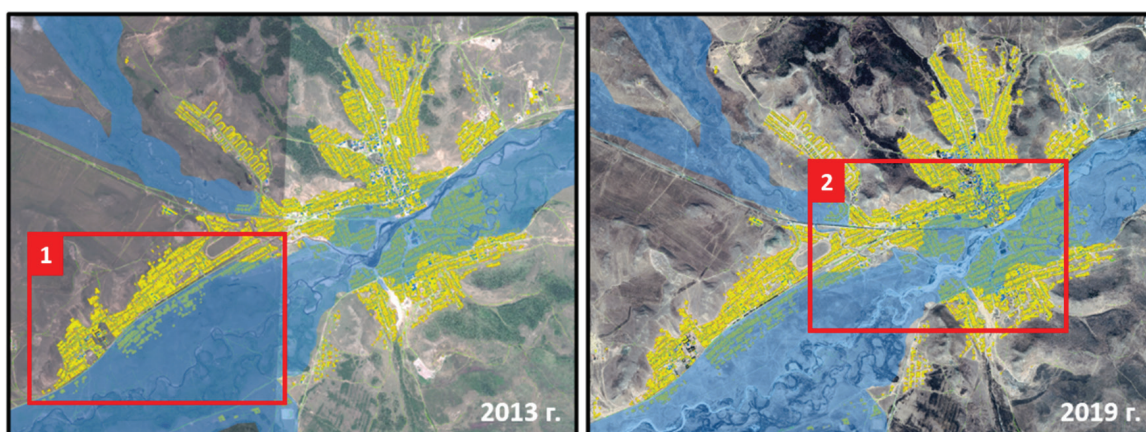


Рис. 3. Изображение пгт Агинское с дешифрированными объектами застройки и наложенной опасной зоной в пределах ЗОУИТ и зоной затопления 1 %-й вероятности / **Fig. 3.** Image of the village Aginskoye with decrypted building objects and an imposed danger zone within the ZOOIT and a 1 % probability flooding zone




Рис. 4. Динамика изменения площадей участков и индивидуальной застройки в пгт Агинское в 2013–2019 гг. / **Fig. 4.** Dynamics of changes in the area of plots and individual buildings in the village Aginskoye from 2013 to 2019

Площадь земельных участков увеличилась с 191,49 га до 214,72 га, а общая площадь индивидуальной застройки – с 254 961 м² до 279 026 м².

При моделировании с использованием нейронных сетей всегда имеется огромное количество вариантов и конфигураций алгоритмов и параметров, влияющих на производительность выбранного решения и качество получаемого результата. Для оценки качества и производительности работы нейронной

сети используются разнообразные метрики, дающие возможность выполнить сравнение разных применяемых схем моделирования. Большинство метрик базируются на описании в терминах матрицы ошибок (Confusion matrix), имеющих обозначения, приведённые на рис. 5.

Таким образом, ошибки бывают двух классов: False Positive (FP), или ошибка 1-го рода, и False Negative (FN) – ошибка 2-го рода.

		Истинное значение	
		y=1	y=0
Предсказанное значение	y'=1	True Positive (TP)	False Positive (FP) Ложное срабатывание
	y'=0	False Negative (FN) Пропуск цели	True Negative (TN)

Рис. 5. Матрица ошибок / Fig. 5. Confusion matrix

F-мера – агрегированный критерий, объединяющий precision и recall, равный их среднему гармоническому. В критерии F принимается во внимание вес precision или recall, т. к. максимальные значения данных метрик одновременно не достижимы:

$$F_{\beta} = (1 + \beta^2) \cdot \frac{\text{precision} \cdot \text{recall}}{(\beta^2 \cdot \text{precision}) + \text{recall}}$$

где β – вес точности в F-мере.

Самый сбалансированный вариант – это критерий F1 при $\beta=1$. В этом случае и precision, и recall достигают совместного максимума. Соответственно, F1-мера является универсальным и сбалансированным критерием оценки качества моделей классификации.

После процесса обучения и определения эффективности и выбора оптимальной архитектуры нейросети её эффективность

определена по «матрице ошибок» (Confusion matrix). Отмечено неравномерное качество определения объектов различных классов, что отображено на рис. 6.

Классы «реки», «участки» и «неклассифицированные объекты» показали высокую точность при обучении, классы «строения» и «дороги» – более низкую точность, а класс «ограждения» – самую низкую точность, что связано с проблемой несбалансированности выборки, т. е. с различием размеров объектов, попадающих в разные классы. Даже процесс аугментации, направленный на искусственное увеличение выборки посредством различных искажений и растяжений, не дал высоких результатов. Это связано с тем, что ограждения имеют малую толщину и протяжённый линейный размер, что затрудняет их распознавание, по сравнению с другими объектами. Более того, сеть часто неправильно определяла ограждение как часть участка, что видно на матрице как значение меры $F1=0,13$.

В некоторых случаях сеть ошибочно определяла строения как участки ($F1=0,06$). Для улучшения точности сегментации ограждений внесены корректировки в исходную разметку обучающей выборки, а маски данного класса увеличены в размере, что привело к улучшению точности выделения классов ограждений и распознавания участков, огороженных заборами (рис. 6).

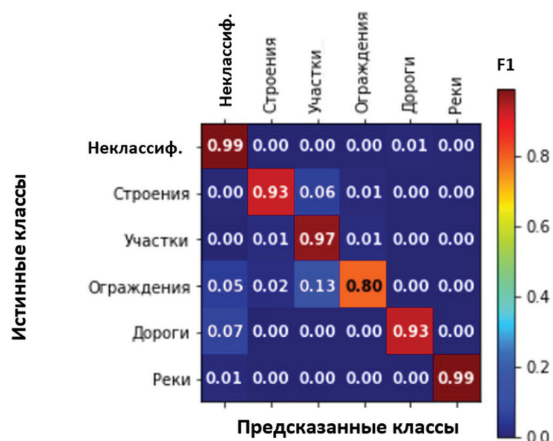
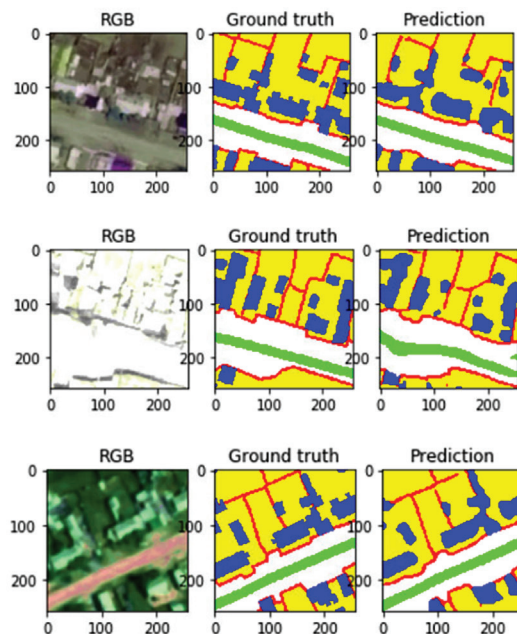


Рис. 6. Матрица ошибок разделения классов и сравнительные образцы работы алгоритма сегментации / Fig. 6. Class separation confusion matrix and comparative examples of the segmentation algorithm



Сравнение истинных и предполагаемых значений показало 97 % точности для земельных участков, 93 % точности для строений, 80 % точности для ограждений. Низкая точность при выделении ограждений, как уже сказано ранее, обусловлена их малой толщиной и линейной протяжённостью.

Разработанная программа¹ позволила идентифицировать застройку на космических

снимках, что способствовало определению её количественного состава, а также выявлению появления новых объектов недвижимости (рис. 7).

Программа работает через Yupiter Notebook на операционных системах: Windows 7, 8, 10, 11. Язык программирования: Python. Объём программы: 50,5 Kb (рис. 8).



Рис. 7. Фрагмент снимка г. Хилок до и после обработки /
Fig. 7. Fragment of the image of Khilok before and after processing¹

¹ Свидетельство о государственной регистрации программы для ЭВМ № 2024618101 Российская Федерация. Программа для дешифрирования объектов застройки на аэрофотоснимках и спутниковых снимках высокого пространственного разрешения : № 2024616752 : заявл. 01.04.2024 : опубл. 09.04.2024 / Д. В. Кочев, К. А. Курганович; заявитель – ФГБОУ ВО «Забайкальский государственный университет».

```

class SegNet(nn.Module):
    # SegNet network
    @staticmethod
    def weight_init(m):
        if isinstance(m, nn.Linear):
            torch.nn.init.kaiming_normal(m.weight.data)

    def __init__(self, in_channels=IN_CHANNELS, out_channels=N_CLASSES):
        super(SegNet, self).__init__()
        self.pool = nn.MaxPool2d(2, return_indices=True)
        self.unpool = nn.MaxUnpool2d(2)

        self.conv1_1 = nn.Conv2d(in_channels, 64, 3, padding=1)
        self.conv1_1_bn = nn.BatchNorm2d(64)
        self.conv1_2 = nn.Conv2d(64, 64, 3, padding=1)
        self.conv1_2_bn = nn.BatchNorm2d(64)

        self.conv2_1 = nn.Conv2d(64, 128, 3, padding=1)
        self.conv2_1_bn = nn.BatchNorm2d(128)
        self.conv2_2 = nn.Conv2d(128, 128, 3, padding=1)
        self.conv2_2_bn = nn.BatchNorm2d(128)

        self.conv3_1 = nn.Conv2d(128, 256, 3, padding=1)
        self.conv3_1_bn = nn.BatchNorm2d(256)
        self.conv3_2 = nn.Conv2d(256, 256, 3, padding=1)
        self.conv3_2_bn = nn.BatchNorm2d(256)
        self.conv3_3 = nn.Conv2d(256, 256, 3, padding=1)
        self.conv3_3_bn = nn.BatchNorm2d(256)

        self.conv4_1 = nn.Conv2d(256, 512, 3, padding=1)
        self.conv4_1_bn = nn.BatchNorm2d(512)
        self.conv4_2 = nn.Conv2d(512, 512, 3, padding=1)
        self.conv4_2_bn = nn.BatchNorm2d(512)
        self.conv4_3 = nn.Conv2d(512, 512, 3, padding=1)
        self.conv4_3_bn = nn.BatchNorm2d(512)

        self.conv5_1 = nn.Conv2d(512, 512, 3, padding=1)
        self.conv5_1_bn = nn.BatchNorm2d(512)
        self.conv5_2 = nn.Conv2d(512, 512, 3, padding=1)
        self.conv5_2_bn = nn.BatchNorm2d(512)

```

```

# Parameters
WINDOW_SIZE = (256, 256) # Patch size
STRIDE = 32 # Stride for testing
IN_CHANNELS = 3 # Number of input channels (e.g. RGB)
FOLDER = "d:/DeepVetsForEO/" # Replace with your "/path/to/the/ISPRS/dataset/folder/"
BATCH_SIZE = 10 # Number of samples in a mini-batch

LABELS = ["River", "Roads", "Uchaastki", "Zabori", "Buildings"] # Label names
N_CLASSES = len(LABELS) # Number of classes
WEIGHTS = torch.ones(N_CLASSES) # Weights for class balancing
CACHE = True # Store the dataset in-memory

MAIN_FOLDER = FOLDER + 'Nerchinsk/'
DATA_FOLDER = MAIN_FOLDER + 'dataset_mask/cs{}.tif' # same syntax for распознавания
LABEL_FOLDER = MAIN_FOLDER + 'G_truth/gt_{}.tif' # различные данные в виде раstra
ERODED_FOLDER = MAIN_FOLDER + 'G_truth/gt_{}.tif' # классы отгелены черной линией

```

Рис. 8. Фрагмент программы для ЭВМ на языке программирования Python / Fig. 8. A fragment of a computer program in the Python programming language

Программа состоит из модуля обучения и модуля инференс. Модуль для обучения включает список и параметры требуемых блоков для работы нейронной сети.

Для отображения объектов застройки и других объектов назначается цвет на получаемом растровом изображении.

0 : (255, 255, 255), # Неклассифицированный объект (white).

1 : (255, 255, 0), # Участки (yellow).

2 : (0, 255, 255), # Лес (cyan).

3 : (255, 0, 0), # Ограждения (red).

4 : (0, 0, 255) # Строения (blue).

Во время инференса производится ряд следующих действий при обработке изображений:

1) из указанной папки инференса последовательно обрабатываются все имеющиеся изображения разных форматов;

2) после обработки сохраняются два файла: tif – полный растр с геопривязкой, png – растр для просмотра результата.

Выводы. На основе проведенных исследований можно сделать несколько важных выводов относительно рационального использования паводкоопасных территорий.

Использование современных методов дистанционного зондирования Земли в сочетании с алгоритмами глубокого обучения позволяет значительно повысить эффективность и точность картирования хозяйственной деятельности в этих зонах.

Применение алгоритмов свёрточных нейронных сетей, таких как U-Net, позволило автоматизировать процесс дешифриро-

вания объектов застройки, приближая его по качеству к визуальному анализу, что является значительным преимуществом, учитывая временные и трудовые затраты традиционных методов. Тем не менее исследование показало, что точность классификации объектов может варьироваться в зависимости от их характеристик, таких как размер и форма. Сравнение истинных значений и предсказанных показало 97 % точности для земельных участков, 93 % точности для строений, 80 % точности для ограждений.

Результаты исследования демонстрируют, что интеграция данных различных пространственных разрешений и источников (например, спутниковых снимков и данных БПЛА) в модели глубокого обучения может существенно улучшить качество анализа. Это особенно важно для управления и планирования территорий, подверженных паводкам, что подтверждается высокой точностью классификации и идентификации объектов застройки, полученной в данном исследовании.

Таким образом, внедрение передовых технологий дистанционного зондирования и искусственного интеллекта в географические исследования открывает новые возможности для эффективного управления земельными ресурсами и снижения рисков, связанных с опасными природными явлениями, в частности с наводнениями. Соответственно, подтверждается необходимость дальнейшего развития и применения данных методик в практике территориального планирования и управления.

Список литературы

1. Богатырева А. А., Виноградова А. Р., Тихомирова С. А. Исследование способности к Transfer Learning свёрточных нейронных сетей, обученных на Imagenet // Международный журнал прикладных и фундаментальных исследований. 2019. № 7. С. 106–111.
2. Галанов А. Э., Селюкова Г. П. Нейронные сети и нейронные технологии // Актуальные вопросы науки и хозяйства: новые вызовы и решения: сб. ст. LIII Междунар. студ. науч.-практ. конф. Тюмень: Государственный аграрный университет Северного Зауралья, 2019. С. 399–405.
3. Кочев Д. В. Геоэкологическое картирование застройки на паводкоопасных территориях городов Шилки и Нерчинска Забайкальского края с использованием спектрального индекса NDBI и нейронной сети // Вестник Забайкальского государственного университета. 2024. Т. 30, № 1. С. 28–39.
4. Курганович К. А., Шаликовский А. В., Босов М. А., Кочев Д. В. Применение алгоритмов искусственного интеллекта для контроля паводкоопасных территорий // Водное хозяйство России: проблемы, технологии, управление. 2021. № 3. С. 6–24.
5. Сеничев А. В., Новикова А. И., Васильев П. В. Сравнение глубокого обучения с традиционными методами компьютерного зрения в задачах идентификации дефектов // Молодой исследователь Дона. 2020. № 4. С. 64–67.
6. Солодухин А. А. Забайкальский край – паводкоопасный регион // Техносферная безопасность Байкальского региона: сб. ст. междунар. науч.-практ. конф. Чита: ЗабГУ, 2017. С. 24–32.
7. Шаликовский А. В. Основы рационального использования паводкоопасных территорий: автореф. дис. ... д-ра геогр. наук: 25.00.36. Чита, 2004. 40 с.

8. Girshick R., Donahue J., Darrell T., Malik J. Region-based convolutional networks for accurate object detection and semantic segmentation // *IEEE Trans Pattern Anal Mach Intell.* 2016. No. 38. P. 142–158.
9. Goodfellow I., Bengio Y., Courville A. *Deep learning.* Cambridge (MA): MIT Press, 2016.
10. Graves A., Liwicki M., Fernandez S., Bertolami R., Bunke H., Schmidhuber J. A. Novel connectionist system for improved unconstrained handwriting recognition // *IEEE Trans Pattern Anal Mach Intell.* 2009. No. 31. P. 855–868.
11. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).* 2016.
12. Hinton G. E., Osindero S., Teh Y. W. A Fast-learning algorithm for deep belief nets // *Neural Comput.* 2006. No. 18. P. 1527–1554.
13. Hu W., Huang Y., Wei L., Zhang F., Li H. Deep convolutional neural networks for hyperspectral image classification // *J Sens.* 2015. No. 2. P. 3–12.
14. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. Текст: электронный // *Adv Neural Inf Process Syst* 25. 2012. URL: <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neuralnetworks.pdf> (дата обращения: 12.05.2024).
15. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. Текст: электронный // *arXiv.* 2015. URL: <https://arxiv.org/pdf/1409.1556.pdf> (дата обращения: 12.05.2024).

References

1. Bogatyreva A. A., Vinogradova A. R., Tikhomirova S. A. Investigation of the Transfer Learning ability of convolutional neural networks trained on Imagenet. *International Journal of Applied and Fundamental Research*, no. 7, pp. 106–111, 2019. (In Rus.)
2. Galanov A. E., Selyukova G. P. Neural networks and neural technologies // *Actual issues of science and economics: new challenges and solutions: sat. art. LIII International Student Scientific and Practical Conference.* Tyumen: State Agrarian University of the Northern Urals, 2019. P. 399–405. (In Rus.)
3. Kochev D. V. Geoecological mapping of buildings in flood-prone areas of the cities of Shilka and Nerchinsk of the Trans-Baikal Territory using the NDBI spectral index and a neural network. *Transbaikal State University Journal*, vol. 30, no. 1, pp. 28–39, 2024. (In Rus.)
4. Kurganovich K. A., Shalikovskiy A. V., Bosov M. A., Kochev D. V. Application of artificial intelligence algorithms for flood-prone areas control. *Water Management of Russia: Problems, Technologies, Management*, no. 3, pp. 6–24, 2021. (In Rus.)
5. Senichev A. V., Novikova A. I., Vasiliev P. V. Comparison of deep learning with traditional methods of computer vision in problems of defect identification. *Young Researcher of the Don*, no. 4, P. 64–67, 2020. (In Rus.)
6. Solodukhin A. A. Zabaikalsky Krai – flood-prone region. *Technosphere safety of the Baikal region: collection of articles international scientific and practical conference.* Chita: ZabGU, 2017. Pp. 24–32. (In Rus.)
7. Shalikovskiy A. V. Fundamentals of rational use of flood-prone territories: abstract. ... *Doctor of Geographical Sciences: 25.00.36.* Chita, 2004. 40 p. (In Rus.)
8. Girshick R., Donahue J., Darrell T., Malik J. Region-based convolutional networks for accurate object detection and semantic segmentation. *IEEE Trans Pattern Anal Mach Intell*, no. 38, pp. 142–158, 2016. (In Eng.)
9. Goodfellow I., Bengio Y., Courville A. *Deep learning.* Cambridge (MA): MIT Press, 2016. (In Eng.)
10. Graves A., Liwicki M., Fernandez S., Bertolami R., Bunke H., Schmidhuber J. A. Novel connectionist system for improved unconstrained handwriting recognition. *IEEE Trans Pattern Anal Mach Intell*, no. 31, pp. 855–868, 2009. (In Eng.)
11. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).* 2016. (In Eng.)
12. Hinton G. E., Osindero S., Teh Y. W. A Fast-learning algorithm for deep belief nets. *Neural Comput*, no. 18, pp. 1527–1554, 2006. (In Eng.)
13. Hu W., Huang Y., Wei L., Zhang F., Li H. Deep convolutional neural networks for hyperspectral image classification. *J Sens*, no. 2, pp. 3–12, 2015. (In Eng.)
14. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst* 25. 2012. Web. 12.05.2024. <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neuralnetworks.pdf>. (In Eng.)
15. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv.* 2015. Web. 12.05.2024. <https://arxiv.org/pdf/1409.1556.pdf>. (In Eng.)

Информация об авторе

Кочев Денис Владимирович, аспирант, старший преподаватель, зав. лабораториями, Забайкальский государственный университет, г. Чита, Россия; denis.ko4ev@yandex.ru. Область научных интере-

сов: геоэкология, дистанционное зондирование Земли, геоинформационные системы, беспилотные летательные аппараты, радиолокация, машинное обучение, нейронные сети, географические науки.

Information about the author

Kochev Denis V., postgraduate, senior lecturer, head of laboratories, Transbaikal State University, Chita, Russia; denis.ko4ev@yandex.ru. Research interests: geoecology, remote sensing of the earth, geographic information systems, unmanned aerial vehicles, radar, machine learning, neural networks, geographical sciences.

Для цитирования

Кочев Д. В. Геоэкологическое картирование селитебных территорий Забайкальского края с использованием свёрточной нейронной сети // Вестник Забайкальского государственного университета. 2024. Т. 30, № 3. С. 27–37. DOI: 10.21209/2227-9245-2024-30-3-27-37.

For citation

Kochev D. V. Geoecological Mapping of Urbanized Territories of the Transbaikal Territory Using a Convolutional Neural Network // Transbaikal State University Journal. 2024. Vol. 30, no. 3. P. 27–37. DOI: 10.21209/2227-9245-2024-30-3-27-37.