

Двухэтапный подход к распознаванию коррозии металлических конструкций с использованием сверточных нейронных сетей в ходе проведения инспекций промышленных объектов

К. Д. Русаков¹ ✉, А. В. Чехов¹

¹ Институт проблем управления им. В.А. Трапезникова РАН,
ул. Профсоюзная, д. 65, стр. 1, г. Москва 117342, Российская Федерация

✉ e-mail: rusakov.msk@yandex.ru

Резюме

Цель исследования: Распознавание коррозии на металлических конструкциях является серьезной проблемой в проведение инспекций промышленных объектов. Существующие подходы к анализу изображений имеют тенденцию использовать все изображения для распознавания участков, поврежденных коррозией, что не подходит как для структурного анализа, так как процент ошибок при таком подходе очень велик. В условиях прогнозирования коррозии по всему изображению возможны ошибки, связанные с прогнозируемой маской не на металлической конструкции. В связи с этим необходимо удалять результаты прогнозирования положительного класса для участков, поврежденных коррозией, но не размещенных на металлической конструкции. Поэтому в данной работе авторы разработали двухэтапный подход к распознаванию коррозии металлических конструкций, тем самым достигая цель – повышение точности распознавания.

Методы. В этой статье мы применяем две модели глубокого обучения, ориентированные на семантическую сегментацию (DeepLabv3, BiSeNetV2) для обнаружения коррозии, которые работают лучше с точки зрения точности и времени и требуют меньшего количества аннотированных образцов по сравнению с другими глубокими моделями, например, Unet, FCN, Mask-RCNN. В работе предложен новый подход к распознаванию металлических участков, поврежденных коррозией, на основе совмещения двух сверточных нейронных сетей для более точного пиксельного предсказания глубинными моделями архитектуры DeepLabv3 и BiSeNetV2.

Результаты. В ходе экспериментальных исследований проводился расчет точности и F1 меры с использованием моделей FCN, Unet, Mask-RCNN, а также предложенного подхода. На основании полученных результатов был сделан вывод о том, что предложенный подход состоящий в совмещении сетей DeepLabv3 и BiSeNetV2 на 3 % повышает точность и F1 меру для алгоритма Unet, на 10% точность и 2% F1 меру для Mask R-CNN и на 12 % точности и 4 % F1 меру для FCN сети. Экспериментальные результаты и сравнения с реальными наборами данных подтверждают эффективность предложенной схемы даже для очень сложных изображений с множеством типов дефектов. Производительность оценивалась на базе данных, аннотированной экспертами.

Заключение. В статье проведен анализ существующих решений в области распознавания металлических конструкций, поврежденных коррозией, и выявлены недостатки существующих решений, основанных либо на детекции очагов коррозии, либо на попиксельной сегментации полного изображения. В данной работе предложен новый подход к распознаванию металлических участков, поврежденных коррозией, на основе совмещения двух сверточных нейронных сетей для более точного пиксельного предсказания DeepLabv3 и BiSeNetV2. Производительность оценивается на базе данных, аннотированной экспертами по метрикам Precision и F1-score

Ключевые слова: вертикальные инспекции; семантическая сегментация; глубокое обучение; обнаружение коррозии; сверточные нейронные сети.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Русаков К. Д., Чехов А. В. Двухэтапный подход к распознаванию коррозии металлических конструкций с использованием сверточных нейронных сетей в ходе проведения инспекций промышленных объектов // Известия Юго-Западного государственного университета. 2021; 25(3): 152-166. <https://doi.org/10.21869/2223-1560-2021-25-3-152-166>.

Поступила в редакцию 24.08.2021

Подписана в печать 30.09.2021

Опубликована 21.10.2021

Two-step Approach to Corrosion Detection of Metal Structures Using Convolutional Neural Networks When Inspecting Industrial Facilities

Konstantin D. Rusakov ¹ ✉, Anton V. Chekhov ¹

¹ V. A. Trapeznikov Institute of Control Sciences of Russian Academy of Sciences
65 Profsoyuznaya str., Moscow 117997, Russian Federation

✉ e-mail: rusakov.msk@yandex.ru

Abstract

Purpose of research. Corrosion recognition on metal structures is a serious problem in conducting inspections of industrial facilities. Existing approaches to image analysis use all images to recognize areas damaged by corrosion, which is not suitable for structural analysis, since the percentage of errors in this approach is very large. Under conditions of corrosion prediction throughout the image, errors related to predictive mask not on metal structure are possible. Therefore, it is necessary to delete the results of positive class prediction for areas damaged by corrosion but not placed on metal structure. Therefore, in this work, the authors have developed two-step approach for recognizing corrosion of metal structures, thereby achieving the goal of improving recognition accuracy.

Methods. We implement two deep learning models focused on Semantic segmentation (DeepLabv3, BiSeNetV2) for corrosion detection that work better in terms of accuracy and time and require fewer annotated samples compared to other deep models, such as Unet, FCN, Mask-RCNN. A new detection approach to metal areas damaged by corrosion, based on the combination of two convolutional neural networks for more accurate pixel prediction by depth architecture models: DeepLabv3 and BiSeNetV2.

Results. Experimental studies have calculated the accuracy and F1 measures using FCN, Unet, Mask-RCNN models as well as the proposed approach. Based on obtained results, it was concluded that proposed approach of combining DeepLabv3 and BiSeNetV2 networks increases accuracy and F1 measure for Unet algorithm by 3%, accuracy by 10% and 2% F1 measure for Mask R-CNN and by 12% accuracy and 4% F1 measure for FCN network. Experimental results and comparisons with real data sets confirm the effectiveness of proposed scheme even for very complex images with many different defects. Productivity was assessed based on data annotated by experts.

Conclusion. Analyses of existing solutions in the field of recognition of metal structures damaged by corrosion is described. Shortcomings of existing solutions based either on detection of corrosion sites or on pixel segmentation of full image are identified. A new approach to the recognition of metal areas damaged by corrosion based on the combination of two convolutional neural networks for more accurate pixel prediction of DeepLabv3 and BiSeNetV2 is introduced. Production is evaluated based on data annotated by Precision and F1-score metrics experts.

Keywords: vertical inspections; semantic segmentation; deep learning; corrosion detection; convolutional neural networks.

Conflict of interest. *The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.*

For citation: Rusakov K. D., Chekhov A. V. Two-step approach to corrosion detection of metal structures using convolutional neural networks when inspecting industrial facilities. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University.* 2021; 25(3): 152-166 (In Russ.). <https://doi.org/10.21869/2223-1560-2021-25-3-152-166>.

Received 24.08.2021

Accepted 30.09.2021

Published 21.10.2021

Введение

Металлические конструкции широко используются в энергетике, например в линиях электропередач (ЛЭП), инфраструктуре связи (вышках сотовой связи), транспортных инфраструктурах (мосты). Ржавчина и коррозия могут привести к серьезным проблемам с безопасностью. Следовательно, обнаружение металлических дефектов является серьезной проблемой для обеспечения быстрого, эффективного, но также безопасного осмотра, оценки и обслуживания инфраструктуры [1] и борьбы с явлениями разрушения материалов, которые возникают из-за нескольких факторов, таких, как изменение климата и погодные явления, а также проведения инспекций, в том числе с использованием БПЛА [2]. Современные подходы к анализу изображений для обнаружения дефектов основаны на ограничивающих рамках, размещаемых вокруг дефектных областей, чтобы помочь инженерам быстро сосредоточиться на повреждениях [3]. Однако такие подходы не подходят для структурного анализа, поскольку для оценки состояния дефекта требуются несколько показателей (на-

пример, площадь, соотношение сторон, максимальное расстояние). Таким образом, нам нужна более точная классификация на уровне пикселей. Распознавание коррозии в реальном времени необходимо для быстрого осмотра критически важной инфраструктуры, особенно в крупномасштабных структурах.

В настоящее время наблюдается большой интерес к методам глубокого обучения [4, 5, 6, 7, 8], в том числе и в целях обнаружения коррозии. Авторы [9] применяли сверточные нейронные сети (CNN) для идентификации ржавчины по полученным в качестве входных данных 2D-изображениям. Другие подходы используют структуру сверточных нейронных сетей для обнаружения трещин в бетонной и стальной инфраструктуре [10], повреждений дорог [11] и дефектов металлических поверхностей в железных дорогах [12]. Авторы в работе [13] объединяют сверточную нейронную сеть и схему объединения данных Байеса для обнаружения трещин на атомных электростанциях. Основная проблема всех вышеупомянутых подходов состоит в том, что они используют традиционные глубинные модели, такие как сверточные ней-

ронные сети, которые требуют большого количества аннотированных данных. В нашем случае такой сбор – сложная задача, так как аннотация должна выполняться экспертами на пиксельном уровне. По этой причине большинство существующих методов оценивают дефектные области через граничные рамки. Кроме того, существующие подходы попиксельного прогнозирования также не справляются с задачей, так как требуют большого количества изображений для точной работы. Чтобы устранить эти ограничения, мы используем двухэтапный подход к глубокому обучению, на основе нейронных сетей DeepLabv3 [14] и BiSeNetV2 [15] для семантической сегментации. Эффективность конкретных методов уже подтверждена медицинской визуализацией (например, обнаружение опухоли головного мозга) [16].

Материалы и методы

С точки зрения визуального осмотра поверхность, поврежденная коррозией, более шероховатая, чем поверхность некоррозийного участка, и её цвет выглядит как оттенок между красным и коричневым. Поиск коррозионных участков на металлической конструкции – это особый случай семантической сегментации. Во многих случаях обнаружение коррозионных участков на металлических конструкциях гораздо более сложная задача по сравнению с семан-

тической сегментацией объектов, таких как люди, здания и автомобили в городской среде, где формы объектов правильные и четко очерченные. Точно так же объекты на медицинских изображениях хорошо изучены и обычно имеют четко определенные формы с некоторыми вариациями. Дефекты, которые необходимо выявить, очень необычны, например, трещины, проколы и коррозия [17]. Один из подходов к построению архитектур сверточных нейронных сетей для семантической сегментации состоит в выборе структуры кодера и декодера. Предварительно обученная сверточная нейронная сеть, такая как ResNet, используется в качестве кодировщика и изучает отличительные особенности данных. Затем полученный эмбединг (закодированный вектор) подключается к сети декодера, которая прогнозирует фактические пиксели изображения.

В условиях прогнозирования коррозии по всему изображению, возможны ошибки, связанные с прогнозируемой маской не на металлической конструкции. В связи с этим необходимо результаты прогнозирования положительного класса для участков, поврежденных коррозией, но не размещенных на металлической конструкции удалять. Для этих целей будем использовать дополнительную сверточную нейронную сеть для семантической сегментации фона.

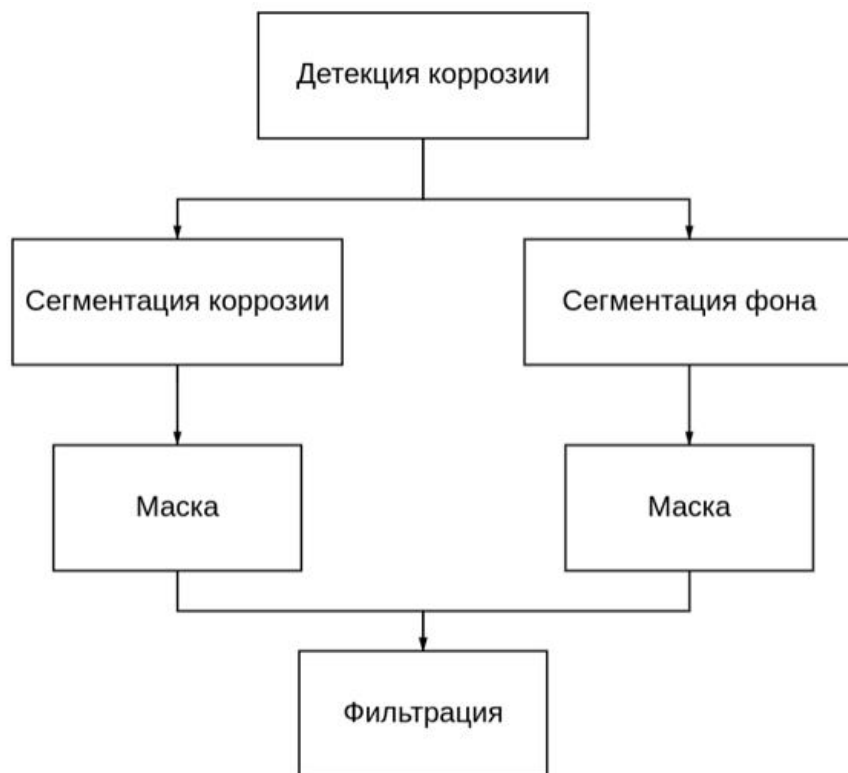


Рис. 1. Блок схема алгоритма детекции коррозии

Fig. 1. Block diagram of corrosion detection algorithm

В задачах прогнозирования маски коррозии металлической конструкции очень важно находить границы поврежденной области, а потому декодер должен работать максимально эффективно. В качестве архитектуры прогнозирования маски коррозии металлической конструкции выбрана DeepLabv3+, содержащая эффективный модуль декодирования для уточнения результатов сегментации, в том числе по границам объектов [14] (рис. 2).

Семантическая информация закодирована в выходном эмбединге кодера DeepLabv3, а модуль декодера позволяет детально восстанавливать границы объекта. Авторы [14] демонстрируют улучшение с точки зрения скоро-

сти и точности путем адаптации модели Xception [18] для задачи семантической сегментации и применения жесткой разделяемой свертки как к модулям пулинга пространственных пирамид, так и к модулям декодера.

Для создания входных изображений были подготовлены 117 изображений разрешением 4056x3040, на которых была размечены все области, подверженные коррозией. На первом шаге подготовки данных, в целях повышения качества все изображения были разбиты на множество мелких изображений размером 256x256.

Данный шаг позволил извлечь максимальное количество информации из изображений высокой четкости для

лучшего распознавания коррозии. На втором шаге была произведена следующая аугментация данных:

- Случайный поворот изображения на угол не более 30 градусов со сдвигом и масштабированием на 20 %.
- Случайное вертикальное и горизонтальное отображение изображений.

- Случайное изменение яркости и контраста на 10 %.

- Оптическое искажение изображения (криволинейное).

- Оптическое искажение сетки изображений.

- Случайные эластичные преобразования изображений.

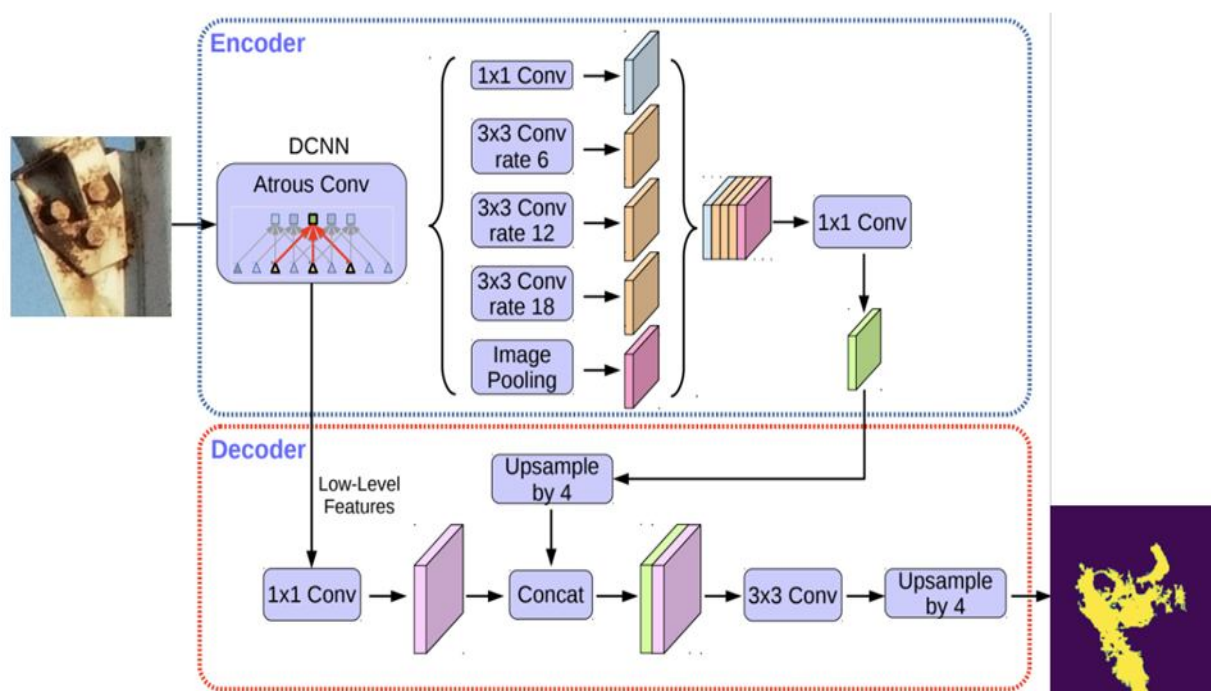


Рис.2. Архитектура DeepLabv3+

Fig. 2. DeepLabv3+ architecture

Следующие обучающие изображения были сгенерированы с использованием процесса аугментации и кропа (рис. 3):

- 2700 изображений металлической конструкции с коррозионным повреждением для обучения;
- 500 изображений металлической конструкции с коррозионным повреждением для валидации.

Сверточная нейронная сеть была настроена на обучение с размером пакета 4 в течение 40 эпох. Механизм ранней остановки использовался для прекращения обучения после того, как не было заметного улучшения в течение 5 последовательных эпох. В результате общее время обучения составило 30 эпох. В конце обучения наша сеть дала среднее значение IoU 0.26 на валидации, а коэффициент Dice достиг 0.34 на валидации (рис. 4).



Рис. 3. Примеры аугментированных изображений

Fig. 3. Examples of augmented images




Рис. 4. Графики качества обучения модели

Fig. 4. Model Training Quality Graphs

В задачах прогнозирования маски металлической конструкции и отделения её от фона также важно находить границы самой металлической конструкции, при этом важна скорость прогнозирования маски, так как это влияет на общую скорость распознавания коррозии.

С этой целью выбрана эффективная и действенная архитектура с хорошим компромиссом между скоростью и точностью, называемая сетью двусторонней сегментации BiSeNetV2 [15]. Эта архитектура включает в себя:

- детальную ветвь с широкими каналами и мелкими слоями для захвата низкоуровневых деталей и генерации

представления объектов с высоким разрешением;

- семантическую ветвь с узкими каналами и глубокими слоями для получения семантического контекста высокого уровня.

В основе структуры BiSeNetV2 три компонента: двухканальная магистраль в фиолетовой пунктирной рамке, слой агрегации в оранжевой пунктирной рамке и бустерная часть в желтой пунктирной рамке. Магистраль с двумя путями имеет Детальную ветвь (синие кубики) и Семантическую ветвь (зеленые кубики). Между тем, числа в кубах – это отношение размера карты объектов к разрешению входных данных (рис. 5).

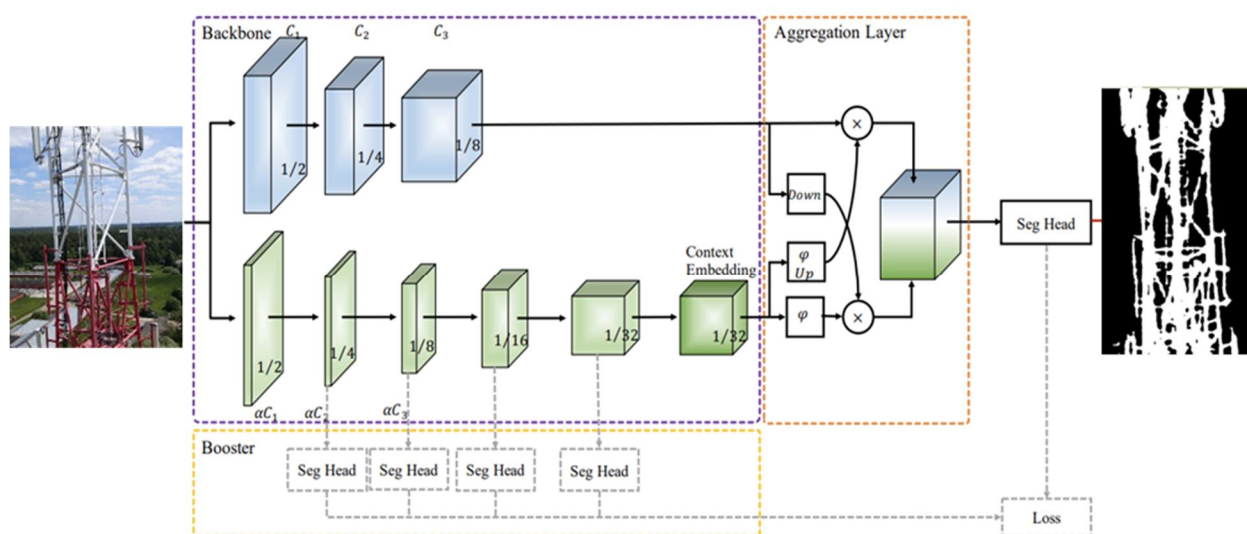


Рис. 5. Архитектура BiSeNetV2

Fig. 5. BiSeNetV2 architecture

В части уровня агрегации применяется двусторонний уровень агрегации. Кроме того, в бустерной части разработаны несколько вспомогательных голов

сегментации, чтобы улучшить производительность сегментации без каких-либо дополнительных затрат на логический вывод.



Рис. 6. Аугментированное изображения для фильтрации фона

Fig. 6. Augmented image for background filtering

Были подготовлены 280 изображений разрешением 5472x3078, на которых была размечена вся металлическая конструкция. Изображения для упрощения разметки снимались только на фоне неба. На первом шаге подготовки данных, в целях повышения скорости все изображения были разбиты на 4 ровных части, при этом фон у каждой части менялся случайно, но, таким образом, чтобы внизу изображения всегда была земля, дома, лес, а вверху изображения – небо. Экспериментально выявлено, что именно данная аугментация позволяет качественно решить задачу фильтрации фона. На втором шаге была произведена следующая аугментация данных:

- случайный поворот изображения на угол не более 30 градусов со сдвигом и масштабированием на 20%;

- случайное вертикальное и горизонтальное отображение изображений;

- случайное изменение яркости и контраста на 10%.

Следующие обучающие изображения были сгенерированы с использованием процесса аугментации и кропа:

- 8462 изображения металлической конструкции для обучения;

- 1256 изображений металлической конструкции для валидации.

Сверточная нейронная сеть была настроена на обучение с размером пакета 4 в течение 120 эпох. Механизм ранней остановки использовался для прекращения обучения после того, как не было заметного улучшения в течение 5 последовательных эпох. В результате общее время обучения составило 95 эпох. В конце обучения реализованная сеть дала среднее значение IoU 0.84 на валидации. Это значение указывает на то, что предсказанные маски покрывают 84% истинной области коррозии в тестовом наборе.

Результаты и их обсуждение

На рис. 7 показана предсказанная маска из изображения в нашем тестовом наборе. Маска окрашена в красный цвет, чтобы выделяться на фоне металлической конструкции. Можно заметить, что прогноз учитывает сложную форму очага коррозии, выделяя только поврежденную коррозией область и игнорируя «чистую» металлическую конструкцию. Вместе с тем, видно, что модель ошибается на фоне изображения и прогнозирует на доме внизу коррозию.

На рис. 8 показана предсказанная маска из изображения в нашем тестовом наборе.

Сравнительные результаты точности и F1 меры [19] показаны в табл. 1. Предлагаемый двухэтапный подход улучшает точность и показатель F1 по сравнению с существующими решениями попиксельной сегментации всего изображения. Метрики измерялись на валидационном наборе данных металлической конструкции – вышке сотовой связи.



Рис. 7. Результат предсказания модели сегментации коррозии

Fig. 7. Prediction result of corrosion segmentation model




Рис. 8. Результат предсказания модели сегментации конструкции

Fig. 8. Prediction result of design segmentation model

Таблица 1

Table 1

Архитектура сети / Network architecture	Precision	F1-score
FCN	0,7	0,71
Unet	0,79	0,72
Mask R-CNN	0,72	0,73
DeepLabv3 + BiSeNetV2	0,82	0,75

Выводы

В статье проведен анализ существующих решений в области распознавания металлических конструкций, поврежденных коррозией, и выявлены недостатки существующих решений, основанных либо на детекции очагов коррозии, либо на попиксельной сегментации полного изображения.

В данной работе предложен новый подход к распознаванию металлических участков, поврежденных коррозией, на основе совмещения двух сверточных нейронных сетей для более точного пиксельного предсказания. Глубинными моделями были DeepLabv3 и BiSeNetV2.

На первом этапе нейронная сеть DeepLabv3 прогнозирует наличие коррозионных участков на металлической конструкции, а на втором этапе нейронная сеть BiSeNetV2 сегментирует металлическую конструкцию. Экспериментальные результаты и сравнения с реальными наборами данных подтверждают эффективность предложенной схемы даже для очень сложных изображений с множеством типов дефектов. Производительность оценивается на базе данных, аннотированной экспертами.

В дальнейшем исследовании планируется оптимизировать [20] две отдельные нейронные сети в одну, для ускорения вычислений.

Список литературы

1. Image processing algorithms for crack detection in welded structures via pulsed eddy current thermal imaging / Z. Liu, G. Lu, X. Liu, X. Jiang, and G. Lodewijks // *IEEE Instrumentation & Measurement Magazine*. 2017. Vol. 20. N. 4. P. 34–44.
2. An application of swarm of quadcopters for searching operations / П.В. Мещеряков, П.М. Трефилов, А.В. Чехов, С.А. Диане, К.Д. Русаков, Е.А. Лесив, М.А. Колодочка, К.О. Щукин, А.К. Новосельский, Е.И. Гончарова // *IFAC-PapersOnLine*. Sozopol, Bulgaria: Elsevier, 2019. Vol. 52, is. 25. P. 14-18 .
3. Automatic crack detection for tunnel inspection using deep learning and heuristic image post-processing / E. Protopapadakis, A. Voulodimos, A. Doulamis, N. Doulamis, T. Stathaki // *Applied Intelligence*. 2019. Vol. 49. No. 7. P. 2793–2806.

4. Вычислительный метод распознавания образов по видеоизображениям с использованием глубоких нейронных сетей со сверточными и рекуррентными слоями с приложениями для транспортных систем / О.С. Амосов, С.Г. Амосова, С.В. Жиганов, Ю.С. Иванов // Информатика и системы управления. 2019. № 1 (59). С. 18-35.

5. Амосов О.С., Амосова С.Г. The Neural Network Method for Detection and Recognition of Moving Objects in Trajectory Tracking Tasks according to the Video Stream // Proceedings of the 26th Saint Petersburg International Conference on Integrated Navigation Systems (ICINS-2019). СПб.: Institute of Electrical and Electronics Engineers Inc, 2019. С. 43-46.

6. 1-D convolutional neural network based on the inner ear principle to automatically assess human's emotional state / Topical Problems of Agriculture, Civil and Environmental Engineering (TPACEE 2020) / А.О. Исхакова, Д.А. Вольф, Р.Р. Галин, М.В. Мамченко // E3S Web of Conferences. Moscow: E3S Web Conf., 2020. Vol. 224.

7. Амосов О.С., Амосова С.Г., Иочков И.О. Вычислительный метод на основе глубоких нейронных сетей для обнаружения и классификации дефектов, возникающих в заклепочных соединениях авиационной техники // Материалы 12-й Международной конференции «Управление развитием крупномасштабных систем» (MLSD'2019, Москва). М.: ИПУ РАН, 2019. С. 736-738.

8. Бобырь М. В. Проектирование нейронных и нечетких моделей в области вычислительной техники и систем управления. М.: Аргамак-Медиа, 2018. 110 с.

9. Corrosion Identification of Fittings Based on Computer Vision / Z. Tian, G. Zhang, Y. Liao, R. Li, F. Huang // International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM). 2019. P. 592-597. <https://doi.org/10.1109/AIAM48774.2019.00123>.

10. Young-Jin Cha, Wooram Choi, Oral Buyukozturk, " Deep learning-based crack damage detection using convolutional neural networks // Computer-Aided Civil and Infrastructure Engineering. 2017. Vol. 32. No. 5. P. 361– 378.

11. Road crack detection using deep convolutional neural network / L. Zhang, F. Yang, Y.D. Zhang, Y. J. Zhu // IEEE international conference on image processing (ICIP). IEEE, 2016. P. 3708–3712.

12. Soukup D., Huber-Mork R. Convolutional neural networks for steel surface defect detection from photometric stereo images, in International Symposium on Visual Computing. Springer, 2014. P. 668–677.

13. Fu-Chen Chen, Mohammad R Jahanshahi. Nbcnn: Deep learning-based crack detection using convolutional neural network and naïve bayes data fusion // IEEE Transactions on Industrial Electronics. 2017. Vol. 65. N. 5. P. 4392–4400.

14. Chen LC., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. In: Ferrari V., Hebert M., Sminchisescu C., Weiss Y. (eds) Computer Vision – ECCV 2018. ECCV 2018. Lecture Notes in Computer Science. Vol 11211. Springer, Cham.

15. Yu Changqian, Gao Changxin, Wang, Jingbo, Yu, Gang, Shen Chunhua, Sang Nong. BiSeNet V2: Bilateral Network with Guided Aggregation for Real-time Semantic Segmentation. 2020

16. Automatic brain tumor detection and segmentation using u-net based fully convolutional networks / H. Dong, G. Yang, F. Liu, Y. Mo, Y. Guo // Annual conference on medical image understanding and analysis. Springer, 2017. P. 506–517.

17. Das S., Hollander C. D., Suliman S. Automating Visual Inspection with Convolutional Neural Networks // Annual Conference of the PHM Society, 2019. N. 11(1).

18. Chollet F.: Xception: Deep learning with depthwise separable convolutions. In: CVPR. 2017.

19. Воротнев Д. В., Голованов Р. В. Методика обучения бинарных классификаторов в задачах сегментации изображений // Известия высших учебных заведений. Электроника. 2019. Т. 24. № 3. С. 279-290. <https://doi.org/10.24151/1561-5405-2019-24-3-279-290>.

20. Бобырь М. В., Ноливос С. К. А., Матиез Л. А. С. Алгоритм ускоренной обработки изображений в системах технического зрения интеллектуальных мобильных роботов // Медико-экологические информационные технологии - 2020 : сборник научных статей по материалам XXIII Международной научно-технической конференции: в 2 ч. Курск, 2020. С. 200-205.

References

1. Liu Z., Lu G., Liu X., Jiang X., Lodewijks G. Image processing algorithms for crack detection in welded structures via pulsed eddy current thermal imaging. *IEEE Instrumentation & Measurement Magazine*, 2017, vol. 20, no. 4, pp. 34–44.

2. Meshcheryakov R.V., Trefilov P.M., Chekhov A.V., Diana S.A., Rusakov K.D., Levitskiy E.A., Kolodochka M.A., Shchukin K.O., Novoselsky A.K., Goncharova E.I. An application of swarm of quadcopters for searching operations. *IFAC-PapersOnLine*. Sozopol, Bulgaria, 2019, vol. 52, is. 25, pp. 14-18 .

3. Protopapadakis E., Voulodimos A., Doulamis A., Doulamis N., Stathaki T. Automatic crack detection for tunnel inspection using deep learning and heuristic image post-processing. *Applied Intelligence*, 2019, vol. 49, no. 7, pp. 2793–2806.

4. Amosov O.S., Amosova S.G., Zhiganov S.V., Ivanov Yu.S. Vychislitel'nyi metod raspoznavaniya obrazov po videoizobrazheniyam s ispol'zovaniem glubinykh neironnykh setei so svertochnymi i rekurrentnymi sloyami s prilozheniyami dlya transportnykh sistem [Computational method of image recognition from video images using deep neural networks with convolutional and recurrent layers with applications for transport systems]. *Informatika i sistemy upravleniya = Informatics and Control Systems*, 2019, no. 1 (59), pp. 18-35.

5. Amosov O.S., Amosova S.G. The Neural Network Method for Detection and Recognition of Moving Objects in Trajectory Tracking Tasks according to the Video Stream. *Proceedings of the 26th Saint Petersburg International Conference on Integrated Navigation Systems (ICINS-2019)*. Saint Petersburg, 2019, pp. 43-46.

6. Iskhakova A.O., Wolf D.A., Galin R.R., Mamchenko M.V. 1-D convolutional neural network based on the inner ear principle to automatically assess human's emotional state. *Topical Problems of Agriculture, Civil and Environmental Engineering (TPACEE 2020)*. E3S Web of Conferences. Moscow, 2020, vol. 224.

7. Amosov O.S., Amosova S.G., Iochkov I.O. [Computational method based on deep neural networks for the detection and classification of defects arising in riveted joints of aircraft]. *Materialy 12-i Mezhdunarodnoi konferentsii «Upravlenie razvitiem krupnomasshtabnykh sistem» (MLSD'2019, Moskva)* [Materials of the 12th International Conference "Management of Large-Scale Systems Development" (MLSD'2019, Moscow)]. Moscow, IPU RAN Publ., 2019, pp. 736-738 (In Russ).

8. Bobyr M.V. *Proektirovanie neuronnykh i nechetkikh modelei v oblasti vychislitel'noi tekhniki i sistem upravleniya* [Design of neural and fuzzy models in the field of computer technology and control systems]. Moscow, Argamak-Media Publ., 2018. 110 p.

9. Tian Z., Zhang G., Liao Y., Li R., Huang F. Corrosion Identification of Fittings Based on Computer Vision. *International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM)*, 2019, pp. 592-597. <https://doi.org/10.1109/AIAM48774.2019.00123>.

10. Young-Jin Cha, Wooram Choi, and Oral Buyukozturk, Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 2017, vol. 32, no. 5, pp. 361–378.

11. Zhang L., Yang F., Zhang Y.D., Zhu Y. J. Road crack detection using deep convolutional neural network. *IEEE international conference on image processing (ICIP)*. IEEE, 2016, pp. 3708–3712.

12. Soukup D., Huber-Mork R. Convolutional neural networks for steel surface defect detection from photometric stereo images in International Symposium on Visual Computing. Springer, 2014, pp. 668–677.

13. Fu-Chen Chen, Mohammad R Jahanshahi Nbcnn: Deep learning-based crack detection using convolutional neural network and naive bayes data fusion. *IEEE Transactions on Industrial Electronics*, 2017, vol. 65, no. 5, pp. 4392–4400.

14. Chen LC., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. In: Ferrari V., Hebert M., Sminchisescu C., Weiss Y. (eds) *Computer Vision – ECCV 2018*. ECCV 2018. Lecture Notes in Computer Science, 2018, vol 11211. Springer, Cham.

15. Yu Changqian, Gao Changxin, Wang Jingbo, Yu Gang, Shen Chunhua, Sang Nong. BiSeNet V2: Bilateral Network with Guided Aggregation for Real-time Semantic Segmentation. 2020.
16. Dong H., Yang G., Liu F., Mo Y., Guo Y., Automatic brain tumor detection and segmentation using u-net based fully convolutional networks. Annual conference on medical image understanding and analysis. Springer, 2017, pp. 506–517.
17. Das S., Hollander C. D., Suliman, S. Automating Visual Inspection with Convolutional Neural Networks. *Annual Conference of the PHM Society*, 2019, 11(1).
18. Chollet, F.: Xception: Deep learning with depthwise separable convolutions. In: CVPR. 2017.
19. Vorotnev D.V., Golovanov R.V. Metodika obucheniya binarnykh klassifikatorov v zadachakh segmentatsii izobrazhenii [Methodology for teaching binary classifiers in image segmentation problems]. *Izvestiya vysshikh uchebnykh zavedenii. Elektronika = Proceedings of Higher Educational Institutions. Electronics*, 2019, vol. 24, no. 3, pp. 279-290. <https://doi.org/10.24151/1561-5405-2019-24-3-279-290>.
20. Bobyr M. V., Nolivos S. K. A., Matiez L. A. [Algorithm of accelerated image processing in technical vision systems of intelligent mobile robots]. *Mediko-ekologicheskie informatsionnye tekhnologii - 2020. Sbornik nauch-nykh statei po materialam XXIII Mezhdunarodnoi nauchno-tekhnicheskoi konferentsii* [Medico-ecological information technologies - 2020. Collection of scientific articles based on the materials of the XXIII International Scientific and Technical Conference]. Kursk, Southwest State University Publ., 2020, pp. 200-205 (In Russ).

Информация об авторах / Information about the Authors

Русаков Константин Дмитриевич, научный сотрудник, Институт проблем управления им. В.А. Трапезникова РАН, г. Москва, Российская Федерация, e-mail: rusakov.msk@yandex.ru, ORCID: <https://orcid.org/0000-0002-1895-8001>

Konstantin D. Rusakov, Research Associate, V. A. Trapeznikov Institute of Control Sciences of Russian Academy of Sciences, Moscow, Russian Federation, e-mail: rusakov.msk@yandex.ru, ORCID: <https://orcid.org/0000-0002-1895-8001>

Чехов Антон Валерьевич, ведущий эксперт, Институт проблем управления им. В.А. Трапезникова РАН, г. Москва, Российская Федерация, e-mail: achekhov@gmail.com

Anton V. Chekhov, Leading Expert, V. A. Trapeznikov Institute of Control Sciences of Russian Academy of Sciences, Moscow, Russian Federation, e-mail: achekhov@gmail.com