

ДЕФЕКТОСКОПИЯ МЕТАЛЛИЧЕСКИХ ПОВЕРХНОСТЕЙ С ПРИМЕНЕНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

В представленной работе рассматривается задача определения трещин на поверхности по видеозображениям оптико-электронной камеры. Для решения предлагается использовать искусственную нейронную сеть, обученную на массиве изображений, содержащих трещины и без них. В качестве структуры нейросети был выбран сверточный тип, как наиболее подходящий для работы с изображениями. Сформирована сверточная нейронная сеть из двух сверточных слоёв для бинарной классификации изображений. Обучение модели было остановлено на 26 эпохе с численным результатом точности проверки 98%. Для оценки качества модели построена матрица путаницы и сформирован классификационный отчет, показавший, что обученная модель совершает правильные предсказания с вероятностью 96–98%. Написан код программы для распознавания трещин на поверхности по изображениям, выводящий в результате изображение с трещиной и координаты расположения трещины. Разработан алгоритм для постобработки изображения, который выделяет поврежденную зону поверхности, строит контуры трещины и оптимальную по точности траекторию для прохождения сварочного аппарата для устранения трещины. Основные вычисления и написание кода программы были проведены с использованием языка программирования Python.

Дефектоскопия, металл, искусственная нейронная сеть, сверточный тип, бинарная классификация.

DEFECTOSCOPY OF METAL SURFACES USING ARTIFICIAL NEURAL NETWORKS

The presented work considers the problem of determining cracks on a surface from images. For the solution, it is proposed to use an artificial neural network trained on an array of images containing cracks and without them. The convolutional type was chosen as the structure of the neural network as the most suitable for working with images. A convolutional neural network of two convolutional layers was formed for binary image classification. The training of the model was stopped at epoch 26 with a numerical result of 98% verification accuracy. To evaluate the quality of the model, a confusion matrix was constructed and a classification report was generated showing that the trained model makes correct predictions with 96-98% probability. A program code for recognizing surface cracks from images was written, outputting an image with a crack and the coordinates of the crack location. An algorithm for image post-processing is developed that highlights the damaged area of the surface, constructs the crack contours and the optimal trajectory for passing the welding machine to repair the crack. The basic calculations and writing of the program code were performed using the Python programming language.

Defectoscopy, metal, artificial neural network, convolutional type, binary classification.

Введение

В современном мире промышленности и технологического развития, безопасность играет критическую роль, особенно в контексте надежности конструкционных материалов и оборудования. Одним из ключевых вызовов в этой сфере является раннее выявление и оценка трещин на поверхностях материалов, что имеет огромное значение для предотвращения аварий и улучшения долговечности конструкций. Традиционные методы визуального осмотра и анализа, хотя и эффективны, могут быть субъективными, требовать значительного времени и ресурсов специалистов.

В этом контексте, применение искусственных нейросетей (ИНС) становится чрезвычайно актуальным и перспективным подходом к проблеме поиска трещин на основе фото и видеоизображений. ИН, особенно глубокое обучение и сверточные нейросети, обладают уникальной способностью автоматически извлекать сложные характеристики из изображений, что делает их идеальными для задач компьютерного зрения.

Целью работы является разработка автоматизированного устройства для распознавания трещин на поверхности по изображениям

Объектом исследования является комплекс технического зрения – оптико-электронная камера и соответствующее программное обеспечение (ПО).

В работе были поставлены следующие задачи:

- обзор существующих методов диагностики повреждений;
- выбор технических средств для разработки ПО;
- создание эталонной выборки, формирование dataframes;
- создание и обучение модели сверточной ИНС для бинарной классификации изображений;
- оценка качества модели: построение матрицы путаницы и формирование классификационного отчета;
- создание алгоритма обработки изображений с помощью модели, формирование вывода данных и тестирование;
- создание алгоритма постобработки изображения с выделением поврежденной зоны поверхности;
- создание алгоритма построения оптимальной траектории для прохождения сварочного аппарата для устранения трещины.

Проведем краткий обзор современного состояния развития науки и техники. Работа Д. Хопфилда [1] внесла значительный вклад в развитие теории нейронных сетей. Автор предложил новый класс нейронных сетей, способных обучаться и запоминать информацию. Это исследование заложило основы для использования нейронных сетей в решении различных задач, включая распознавание образов.

В исследовании А. Крижевского и Я. Лекуна [2] предложен новый подход к обучению ИНС, основанный на использовании большого количества данных и эффективного алгоритма обратного распространения. Этот подход привел к значительному улучшению качества распознавания изображений и стал основой для многих последующих исследований в области глубокого обучения.

В работа И. Михальчука [3] предложено использование нейронных сетей для поиска ассоциативных правил в больших наборах данных. Этот подход позволил обрабатывать большие объемы информации и находить скрытые закономерности в данных.

Выбор технических средств и разработка программного обеспечения

На этапе подготовки были выбраны следующие технические средства для разработки ПО: язык программирования – Python; среда разработки – Kaggle и Google Colaboratory; библиотеки языка Python: TensorFlow, NumPy, Pandas, Matplotlib, Plotly, Pathlib для функции Path, Sklearn для split, matrix. После обработки изображений эталонной выборки и формирование набора входных данных из их путей программой было найдено 3360 изображений для обучения, 840 для валидации и 1800 для тестирования. Все эти изображения принадлежат к двум классам.

Далее была создана нейронная сеть для бинарной классификации изображений, состоящая из двух сверточных слоёв с максимальным объединением между ними. Сначала модель извлекает признаки изображения с помощью сверточных слоёв, затем уменьшает размер данных с помощью пулинга и в конце выдает вероятность принадлежности к одному из двух классов. В нашем случае обучение модели остановилось на 26 эпохе с численным результатом точности проверки примерно 98%. На рис. 1 представлен график потерь при обучении с течением времени. Потери при обучении постоянно уменьшаются. Однако они достигают точки, когда перестают уменьшаться, а затем начинают расти. После чего обучение модели останавливается и для неё возвращаются веса с лучшей эпохи.


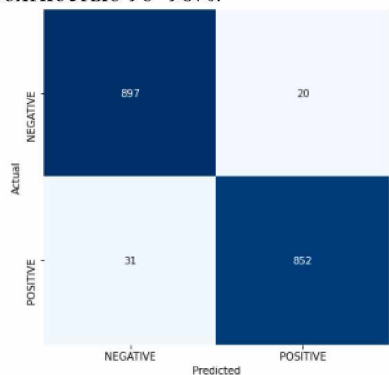


Рис. 1. График потерь при обучении с течением времени

Во время оценки качества модели получен результат точности 97,17%. Матрица путаницы на рис. 2 показывает, что у модели мало неправильных классификаций по сравнению с правильными: 897 отрицательных и 852 положительных правильных классификаций против 31 и 20 неправильных. Отношения количества правильно предсказанных классификаций к непра-

вильным посчитаны и указаны в классификационном отчете на рис. 3. Это означает, что обученная модель совершает правильные предсказания с вероятностью 96–98%.



Classification Report:

	precision	recall	f1-score	support
NEGATIVE	0.97	0.98	0.97	917
POSITIVE	0.98	0.96	0.97	883
accuracy			0.97	1800
macro avg	0.97	0.97	0.97	1800
weighted avg	0.97	0.97	0.97	1800

Рис. 2. Матрица путаницы

Рис. 3. Классификационный отчет

Для тестирования модели был загружен набор данных содержащих 30 изображений поверхности, принадлежащих одному классу. В результате выполнения созданной функции `scan_model` получаем три изображения на рис. 4 и замечаем, что действительно на всех выбранных элементах присутствуют трещины. Также вместе с изображениями выводятся строки, в которых указаны координаты трещин, взятые из имен файлов.




Рис. 4. Результат вывода в консоль изображений, на которых по предсказанию модели присутствуют трещины, и координаты трещин

Для постобработки изображение преобразовали в градации серого, применили фильтр Собеля и фильтр Гаусса, нашли контуры, выбрали самый большой, создали маску контура, получили два изображения с наложенным примерным контуром трещины на поверхности. Используя альфа-канал для регулировки прозрачности, был наложен контур и получено объединенное изображение (рис. 5). Заметим, что полученные контуры трещины совпадают с теми, что видны на исходном изображении поверхности.

Далее, был написан программный алгоритм для поиска точек, соответствующих контуру трещины на изображении, составлен массив координат, по которому происходит построение оптимальной по кривизне траектории с помощью полиномиальной аппроксимации.




Рис. 5. Слева направо: изображение с наложенным первым контуром, затем вторым контуром, объединенное наложением контуров и исходное

Для сравнения были построены графики, полученные аппроксимацией полиномами первой, второй, третьей и пятой степени по кривизне траектории, которые представлены на рис. 6.




Рис. 6. Графики, полученные аппроксимацией полиномами первой, второй, третьей и пятой степени по кривизне траектории (слева направо)

Заметим по рис. 6, что построенная линия повторяет изгибы трещины на исходном изображении и повторяет её лучше с увеличением степени полинома. В нашем случае остановимся на пятой степени, поскольку дальнейшее её увеличение может привести к излишнему ис-

кривлению графика. В результате получаем график оптимальной по точности траектории для прохождения выходным звеном сварочного аппарата для устранения трещины на поверхности.

Выводы

В работе рассматривалась задача определения трещин на поверхности по изображениям с применением искусственной нейронной сети, обученной на массиве изображений, содержащих трещины и без них. В результате выполнения работы была сформирована сверточная нейронная сеть из двух сверточных слоёв для бинарной классификации изображений. Обучение модели было остановлено на 26 эпохе с численным результатом точности проверки 98%. Для оценки качества модели построена матрица путаницы и сформирован классификационный отчет, показавший, что обученная модель совершает правильные предсказания с вероятностью 96–98%. Написан код программы для распознавания трещин на поверхности по изображениям, выводящий в результате изображение с трещиной и координаты расположения трещины. Разработан алгоритм для постобработки изображения, который выделяет поврежденную зону поверхности, строит контуры трещины и оптимальную траекторию для прохождения сварочного аппарата для устранения трещины. Основные вычисления и написание кода программы были проведены с использованием языка программирования Python. Продемонстрирована высокая степень готовности к внедрению разработки в производстве.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Hopfield J. J.* (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79(8), 2554–2558. URL: <https://doi.org/10.1073/pnas.79.8.2554> (дата обращения: 15.02.2024).

2. *Krizhevsky A., Sutskever I., & Hinton G. E.* (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105. URL: <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf> (дата обращения: 25.02.2024).

3. *Michalchuk I.* (2004). Neural network discovery of association rules for large datasets. *International Journal of Intelligent Systems*, 19(1), 51–72. URL: <https://doi.org/10.1002/int.10112> (дата обращения: 05.03.2024).

4. *Заенцев И.В.* Нейронные сети: основные модели/Учебное пособие физ. ф-та. Воронеж. 1999.
5. *Головкин В.А.* Нейронные сети: обучения, организация и применение / М.: ИПРЖР. 2008
6. *Каширина И. Л.* Нейросетевые технологии: Учебно-методическое пособие для вузов /Изд-во ВГУ. 2008. 72 с.
7. *Кочеткова А.С.* Применение нейронных сетей для мониторинга безопасности // Серия 9: Исследования молодых ученых. 2007.
8. *Крисилов В.А.* Представление исходных данных в задачах нейросетевого программирования / Одесса: ОНПУ. 2003.
9. *Круглов В.В.* Нечеткая логика и искусственные нейронные сети / ФИЗМАЛИТ. 2001.
10. *Шахнов В.А., Власов А.И., Кузнецов А.С.* Нейрокомпьютеры: архитектура и схемотехника / М.: Изд-во Машиностроение. 2000. 64 с.
11. *Хайкин С.* Нейронные сети. Полный курс / М.: Вильямс, 2006.

Власов Владимир Михайлович, магистрант Федерального государственного бюджетного образовательного учреждения высшего образования «Национальный исследовательский университет «МЭИ», Россия, г. Москва, вн.тер.г. муниципальный округ Лефортово, ул. Красноказарменная, д. 14, стр. 1, 111250, телефон: +7 (926) 599-91-93, email: vlasov2000vladimir@yandex.ru.

Vlasov Vladimir Mikhailovich, Candidate National Research University «Moscow Power Engineering Institute», 111250, Russia, Moscow, Krasnokazarmennaya str., 14, p. 1, phone: +7 (926) 599-91-93, email: vlasov2000vladimir@yandex.ru.