

ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ИДЕНТИФИКАЦИИ ДЕФЕКТОВ

Соболь Б.В., Васильев П.В., Сеничев А.В., Новикова А.И.

Донской государственный технический университет, г. Ростов-на-Дону, Российская Федерация

Аннотация. В целях повышения автоматизации процесса неразрушающего контроля изделий предложена оптимизированная модель глубокой сверточной нейронной сети для идентификации дефектов на изображениях дорожного полотна. Полученная архитектура нейросети позволяет решать задачи сегментации изображений различной природы, в том числе, в случае ограниченного набора исходных данных. Исследование показало высокую степень повторяемости результатов.

Ключевые слова. Идентификация дефектов, искусственные нейронные сети, сверточные нейронные сети, сегментация дефектов, неразрушающий контроль, дорожное покрытие.

CONVOLUTIONAL NEURAL NETWORKS APPLICATION IN DEFECT IDENTIFICATION PROBLEMS

Sobol B.V., Vasiliev P.V., Senichev A.V., Novikova A.I.

Don State Technical University, Rostov-on-Don, Russian Federation

Abstract. In order to increase an automation of the products non-destructive testing process, a deep convolutional neural network optimized model for identifying defects in road pavement images is proposed. The resulting neural network architecture allows us to solve image segmentation problems of different nature, including in the case of a source data limited set. The study showed a high degree of results repeatability.

Keywords. Defect identification, artificial neural networks, convolutional neural networks, defect segmentation, nondestructive testing, road pavement.

На эксплуатационные характеристики оборудования и его составных элементов отрицательное влияние оказывают различные виды дефектов, возникающие при изготовлении и ремонте (сварке, наплавке, механической и термической обработке, калибровке и т.д.), отливке и прокатке, усталости металла, коррозии, охрупчивании, неправильном технологическом обслуживании, а также при наработке изделия. Решение важной для производственно-эксплуатационных процессов задачи своевременного обнаружения дефектов различной природы (производственно-технических, металлургических, технологических, и др.) достигается путем проведения регулярной диагностики без приостановки и демонтажа объекта процедуры неразрушающего контроля. Идентификация дефектов на ранней стадии их возникновения предотвращает нарушение целостности деталей конструкций и системы в целом, снижая риск отказов, выхода из строя оборудования и возникновения аварийной ситуации [1].

За последние годы в задаче распознавания образов усиливают позиции технологии машинного обучения. Искусственные нейронные сети (ИНС) построены на принципах организации и функционирования биологических нейронных сетей, которые составляют мозг животных. Такие системы «учатся» выполнять задачи, на базе подготовленных примеров. Это инструмент нелинейного математического моделирования, в котором программируемой целевой функцией является нелинейная функция. Часто они используются с целью моделирования сложных связей между входами и выходами для нахождения закономерностей в больших объемах данных. Успешное применение ИНС для решения задач прогнозирования, распознавания образов и управления процессами в различных областях науки и техники обусловлено преимуществами перед другими методами обработки данных, среди которых выделяют автоматизацию процесса представления знаний, снижение затрат и срока разработки, адаптация к изменениям, повышение надежности системы [2, 3].

В работе [4] показано применение нейросетевых технологий в основе экспертной системы для оценки стабильности работы сварщика. Искусственные нейронные сети помогают частично заменить специалиста-эксперта в задачах обнаружения дефектов и их классификации по уровням потенциальной опасности, снижая необходимость присутствия обслуживающего персонала. Как показано, идентификация дефектов протяженных сварных соединений (пор, трещин, кратеров, непроваров и т.д.) возможна в реальном времени по изображениям за счет выявления многофакторной зависимости между входными параметрами (напряжением, током, скоростью сварки, отклонением электрода от оси

шва и т.д.) и качеством формирования геометрических параметров сварных швов. Помимо входных и выходных значений экспертной системы проектируется архитектура искусственной нейронной сети с учетом специфики формирования сварного шва. В обучении нейросети задействована база обучающих векторов, заключающих во входных и выходных параметрах различные сведения о протекании процесса сварки. Появление дефектов прогнозируется путем анализа динамики параметров сварочного процесса в связи с нестабильностью работы специалиста-сварщика или оборудования. Отклонение геометрических параметров сварного соединения от нормальных – критерий оценки стабильности работы оператора сварочного оборудования.

Искусственные нейронные сети третьего поколения с особенной архитектурой – глубокие сверточные нейронные сети (CNN), рассмотренные в работах [5, 6], – один среди наиболее перспективных подходов решения проблемы автоматизированного контроля качества дорожных поверхностей. Архитектура сверточной нейронной сети построена на принципах архитектуры многоуровневого неокогнитрона: на основе низкоуровневых признаков в пределах одного класса формируются высокоуровневые за счет использования небольших по размеру синаптических ядер свертки. В отличие от соединения нейронов двух соседних слоев по принципу «каждый с каждым» улучшаются скоростные характеристики процесса детектирования. Сверточные нейросети широко используются в автоматическом анализе больших объемов изображений для точного выявления отличительных признаков как единичной продукции, так и системы в целом [7, 8].

Исследования [9] показали успешность применения описанной архитектуры в условиях ограниченного количества исходных данных в различных задачах сегментации благодаря высокой степени повторяемости. На вход нейронной сети подается фрагмент изображения объекта контроля, а на выходе составляется карта вероятностей наличия дефекта. При повреждении дорожного полотна на изображениях появляется большое количество шумов и посторонних объектов при малом диапазоне серого цвета и небольшой разнице между фоном и целевым объектом. В результате выделения соответствующих классов обученная и тонко настроенная модель сверточной ИНС позволяет выполнять идентификацию и оценку основных видов дефектов разной формы и размера на изображениях дорожного покрытия.

В изучении класса генеративно-сопоставительных нейросетей (GAN), как инструмента визуализации дефектов в деталях конструкций, доказана их эффективность в автоматическом анализе больших объемов изображений и выявлении отличительных признаков [10]. Смысл данного типа ИНС состоит в одновременной работе двух алгоритмов комбинации нейронных сетей – генератора и дискриминатора. Генератор занимается формированием образов назначенной категории, которые должен распознать дискриминатор. GAN характеризуются воспроизведением изображения на основе параметров, реалистично отражающих целевой объект генерации. Для этих целей возможно применение конечноэлементного моделирования ультразвукового, магнитного и других методов неразрушающего контроля.

Анализ приведенной тематической литературы наглядно показал исключительные преимущества глубоких сверточных нейронных сетей и обоснованность их применения в проводимом исследовании. Для начала необходимо проведение сегментации изображения дорожного полотна с выделением соответствующих классов, которая позволит понять, что является дефектом, а что нет. Для этих целей в настоящее время эффективно используются специально разработанные архитектуры CNN подобно SegNet и U-Net. Сложность задачи заключается в ограниченном диапазоне оттенков серого в изображениях дорожного покрытия, а также в незначительной разнице между целевым объектом и фоном, присутствии шумов и посторонних деталей. Ввиду специфичности обрабатываемых изображений сегментация проводится с применением полностью сверточной нейронной сети (FCNN) со структурой «эн-кодер-декодер», позволяющей на выходе получить бинарное изображение. FCNN образована двумя частями — сверточной, преобразующей входное изображение в многомерное представление признаков, и разверточной, выдающей на основе этих признаков сегментированное изображение. Первая часть построена последовательно расположенными пятью сверточными слоями с наборами фильтров, после чего идут слои субдискретизации. Слои повышающей дискретизации совместно со сверточными слоями позволяют восстановить размер изображения до исходного после прохождения через указанные слои и сформировать карту вероятностей. Используемый набор данных CrackForest состоит из 117 изображений, подразделяющихся на обучающую, тестовую и валидационную (оценивающую качество) выборки. Из обучающей и тестовой выборки для каждого изображения случайным образом выбираются фрагменты размером 64*64. Гамма-коррекция изображения улучшает качество работы нейросети. Оптимальное соотношение фрагментов с дефектом и без него установилось на уровне 95 % к 5 % с учетом дефектов, занимающих не менее 5 % площади изображения. Соотношение размера выборки 15 200 фрагментов обучающей и 3 968 тестовой выборки оптимально для процесса обучения и работы глубокой нейросети. Обучение и оценка работы нейронной сети происходит с применением метрик пересечения между двумя обнаружениями и эквивалентной

бинарной меры схожести. Инициализация весов в слоях FCNN проводится методом Глорота. При нормализации входных распределений каждого слоя уменьшается внутренний ковариационный сдвиг, за счет чего добивается нормализации партии. Обучение методом стохастической оптимизации осуществляется с использованием Adam-алгоритма. Установлено, что оптимальное количество эпох обучения нейронной сети находится на уровне 25 (5 на первом этапе и 20 на втором). Реализация построенной архитектуры FCNN достигнута благодаря фреймворкам Keras и Tensor-Flow. После обучения ИНС производится ее проверка – валидация – на тестовых данных. На вход сети подается каждый фрагмент изображения, на выходе генерируется карта вероятностей наличия дефекта.

Модель глубокой сверточной нейронной сети, полученная в результате обучения и тонкой регулировки, показала достаточно низкий уровень ошибок (по метрикам Dice — 0,7381 и IoU — 0,3488). Доказана способность идентификации дефектов на изображениях дорожного полотна при небольшом количестве исходных данных. Разработанная архитектура обладает высокой степенью повторяемости результатов и может успешно применяться в различных задачах сегментации.

Список использованных источников

1. Тормозов В.С. Анализ методов распознавания образов и машинного обучения для распознавания визуальных образов // Информационные технологии XXI века: сб. науч. труд. – Хабаровск, 2019. С. 354-359.
2. Соболев Б.В., Соловьев А.Н., Рашидова Е.В., Васильев П.В. Идентификация трещиноподобного дефекта и исследование концентрации напряжений в полосе с покрытием // Вестник Пермского национального исследовательского политехнического университета. Механика. 2019. № 4. С. 165-174. DOI: 10.15593/perm.mech/2019.4.16.
3. Соловьев А.Н., Соболев Б.В., Васильев П.В. Ультразвуковая локация внутренних трещиноподобных дефектов в составном упругом цилиндре с применением аппарата искусственных нейронных сетей // Дефектоскопия. - 2016. – №3. – С. 3-9.
4. Лукьянов В.Ф., Кузьменко И.В. Методика обучения экспертной системы оценки стабильности работы сварщика // Вестник ДГТУ. 2014. №4 (79).
5. C. Szegedy et al., "Going deeper with convolutions," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, 2015, pp. 1-9.
6. Wen Chen, Yiping Gao, Liang Gao, Xinyu Li. A New Ensemble Approach based on Deep Convolutional Neural Networks for Steel Surface Defect classification // Procedia CIRP. Volume 72. – 2018. – pp. 1069-1072, doi:10.1016/j.procir.2018.03.264
7. Sattar Dorafshan, Robert J. Thomas, Marc Maguire. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete // Construction and Building Materials. Volume 186, 20 October 2018. – pp. 1031-1045, doi:10.1016/j.conbuildmat.2018.08.011
8. Eisenbach, M., Stricker, R., Seichter, D., Amende, K., Debes, K., Sesselmann, M., Ebersbach, D., Stöckert, U., Gross, H.-M. How to Get Pavement Distress Detection Ready for Deep Learning? A Systematic Approach. in: Int. Joint Conf. on Neural Networks (IJCNN), Anchorage, USA, pp. 2039-2047, IEEE 2017
9. Soloviev A., Sobol B., Vasiliev P. (2019) Identification of Defects in Pavement Images Using Deep Convolutional Neural Networks. In: Parinov I., Chang SH., Kim YH. (eds) Advanced Materials. Springer Proceedings in Physics, vol 224, pp 615-626. Springer, Cham, doi: 10.1007/978-3-030-19894-7_46
10. R. Stricker, M. Eisenbach, M. Sesselmann, K. Debes and H. Gross, "Improving Visual Road Condition Assessment by Extensive Experiments on the Extended GAPS Dataset," 2019 International Joint Conference on Neural Networks (IJCNN), Budapest, Hungary, 2019, pp. 1-8

Исследование выполнено при финансовой поддержке РФФИ в рамках научных проектов № 19-08-00074 и № 19-38-90248.