

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ АВТОМАТИЗАЦИИ КОНТРОЛЯ ВНЕШНЕГО ВИДА ТВЭЛОВ РЕАКТОРОВ БН-800

Игнат Александрович Выхристюк

Конструкторско-технологический институт научного приборостроения СО РАН, 630058, Россия, г. Новосибирск, ул. Русская, 41, старший научный сотрудник, тел. (383)306-62-12, e-mail: uic@ngs.ru

Исследована возможность применения искусственных нейронных сетей (ИНС) для автоматизации контроля внешнего вида твэлов реакторов типа БН-800. Представлены архитектура обучающего множества и алгоритм обнаружения дефектов, не зависящие от конфигурации ИНС и формата входных данных. Приведены основные классы и архитектура ИНС, используемой в экспериментальных исследованиях. Описан процесс обучения и расчет оценки качества работы ИНС. Результаты экспериментальных исследований на имитаторах твэлов (вероятность обнаружения дефектов более 97%) позволяют рассчитывать на то, что более глубокое обучение с использованием большого количества реальных контролируемых изделий позволит полностью автоматизировать процесс контроля.

Ключевые слова: искусственные нейронные сети, анализ изображения, обнаружение дефектов.

USE OF ARTIFICIAL NEURAL NETWORK FOR AUTOMATION OF APPEARANCE CONTROL OF FUEL ELEMENTS OF BN-800 REACTORS

Ignat A. Vykhristyuk

Technological Design Institute of Scientific Instrument Engineering, Siberian Branch of the Russian Academy of Sciences, 630058, Novosibirsk, 41, Russkaya St., Senior Researcher, phone: (383) 306-62-12, e-mail: uic@ngs.ru

The possibility of using artificial neural networks (ANN) to automate the appearance control of the fuel elements of BN-800 type reactors was investigated. The architecture of the training set and the defect detection algorithm independent of the ANN configuration and input data format are presented. The main classes and architecture of the ANN used in experimental studies are given. The training process and the calculation of the quality assessment of the ANN are described. The results of experimental studies on fuel element simulators (the probability of detecting defects is more than 97%) allows us to expect that deeper training using a large number of controlled products will allow us to fully automate the control process.

Key words: artificial neural networks, image analysis, defect detection.

Введение

Автоматизированный бесконтактный контроль качества поверхности является актуальной задачей при производстве ответственных изделий [1], таких как тепловыделяющие элементы (ТВЭЛы), из которых собираются тепловыделяющие сборки (ТВС) для реакторов атомных электростанций.

В России ведутся работы над формированием экологически чистого «замкнутого» ядерного топливного цикла, ключевую роль в котором занимают реакторы на быстрых нейтронах.

ТВЭЛ реакторов типа БН-800 представляет собой цилиндрическую трубку из нержавеющей стали диаметром 6,9 мм и длиной 2 м, внутри которой размещается топливный сердечник (урансодержащие таблетки или порошок). Вокруг ТВЭЛА навита проволока из нержавеющей стали диаметром 1 мм, которая выполняет функцию дистанцирования ТВЭЛОВ друг от друга внутри ТВС.

Целостность оболочки ТВЭЛА играет важнейшую роль в безопасности атомных реакторов, поэтому к качеству оболочки предъявляют жесткие требования. Глубина дефектов поверхности оболочки и дистанцирующей проволоки ТВЭЛОВ реакторов типа БН-800 не должна превышать 20 микрон.

В текущем производственном процессе контроль качества ТВЭЛОВ реакторов типа БН-800 включает в себя контроль внешнего вида (обнаружение жировых загрязнений и механических повреждений наружной поверхности оболочки и дистанцирующей проволоки), выполняющийся вручную. В связи с переходом на новое высокоактивное МОКС-топливо возникает необходимость в минимизации времени контакта рабочего персонала со снаряженными ТВЭЛАМИ, вплоть до полной автоматизации процесса производства и контроля качества.

Созданные ранее системы телевизионного наблюдения поверхности ТВЭЛОВ [2, 3] обладают рядом недостатков, важнейшими из которых является низкая производительность контроля и высокая нагрузка на оператора, производящего удаленный контроль.

Трудность автоматического обнаружения дефектов на поверхности ТВЭЛОВ реакторов типа БН-800 состоит в наличии дистанцирующей проволоки, отбрасывающей тень в различных направлениях и различной степени контрастности.

В настоящее время стремительно развиваются алгоритмы анализа информации, использующие искусственные нейронные сети (ИНС). Такие алгоритмы зачастую применяют для решения задач, формализовать которые полностью практически невозможно. Область применения ИНС постоянно расширяется: от распознавания образов и поиска объектов в видеопотоке до перевода текста, синтеза данных и управления транспортными средствами [4, 5]. Основой эффективности работы ИНС является в первую очередь количество данных, на которых производится ее обучение. Качество данных, а также правильность подобранных методов и алгоритмов обучения влияют, как на эффективность результата, так и на скорость обучения ИНС.

Целью данной работы является исследование возможности автоматического контроля внешнего вида ТВЭЛОВ реакторов типа БН-800 с применением ИНС.

В рамках работы реализован нейросетевой алгоритм обнаружения микродефектов внешней поверхности оболочки и дистанцирующей проволоки ТВЭЛОВ реакторов типа БН-800. Разработана архитектура обучающего множества, независимого от архитектуры ИНС и формата исходных изображений. Создано программное обеспечение, позволяющее производить обучение и проверку эффек-

тивности работы ИНС. Выполнена классификация основных типов дефектов твэлов реакторов типа БН-800. Сформировано первичное обучающее множество и подобрана архитектура ИНС для поиска микродефектов. Произведено обучение ИНС, позволившее использовать ее для поиска микродефектов с вероятностью обнаружения более 97%.

Методы, технологии и материалы

В качестве архитектуры ИНС выбрана сверточная [6], как наиболее популярная и хорошо зарекомендовавшая себя в области анализа изображений [7]. Модель обучения – обучение с учителем [8] – все обучающие данные до начала процесса обучения размечаются и классифицируются человеком. Метод обучения – обратное распространение ошибки [9], реализованный в режиме пакетного градиентного спуска [10].

Разработанное программное обеспечение использует технологию CUDA (Compute Unified Device Architecture) [11] разновидность GPGPU (General-purpose computing on graphics processing units) – технологии параллельных вычислений на графических ускорителях и библиотеку cuDNN (Deep Neural Network library) [12] для работы с ИНС с использованием графических ускорителей производителя NVIDIA.

Для получения реалистичных изображений использовались полноразмерные имитаторы твэлов реакторов типа БН-800 с искусственно нанесенными дефектами и экспериментальный стенд с оптической схемой, аналогичной описанной в работе [2].

Архитектура обучающего множества

В связи с неопределенностью конечной конфигурации регистрирующего оборудования исходными данными для создания обучающей и тестовой выборки было решено считать монохромные изображения произвольного размера и разрядности.

Входными данными для сверточной ИНС является массив, размерности которого определены параметрами входного слоя. Для унификации яркость во входном слое представляется в виде действительного числа в интервале от 0 до 1, где 0 соответствует минимуму (черная точка), 1 – максимуму (белая точка).

В силу малого количества обучающих данных, было принято решение о формировании расширенной обучающей выборки, основанной на исходных изображениях, подвергнутых искажениям (аугментации) [13]. Аугментация изображения может включать в себя небольшие смещения, масштабирование, изменение уровня яркости, повороты и отражения. Диапазоны искажений устанавливаются исходя из условия, что после предельных искажений изображение должно соответствовать своему исходному классу.

Для упрощения выполнения аугментации, а также в силу неопределенности входной размерности ИНС было решено организовать обучающее множество в виде следующей архитектуры.

Исходная выборка (обучающая или тестовая) представляет собой набор, состоящий из N изображений $\{K_i, i \in \{1, \dots, N\}\}$. Каждому изображению K_i соответствует множество, состоящее из M_i позиций $\{P_{ij} = (x_{ij}, y_{ij}, c_{ij}), j \in \{1, \dots, M_i\}\}$, которые определяют значения координат (x_{ij}, y_{ij}) центра исходного обучающего изображения в K_i и класс c_{ij} , соответствующий этому изображению (см. рис. 1).




Рис. 1. Изображение с размеченными позициями.
Классы обозначены цветом. Размеры и форма прямоугольников условны, т.к. зависят от параметров ИНС

При аугментации позиции P_{ij} случайным образом определяются параметры искажений, затем центр позиции (x_{ij}, y_{ij}) , возможно измененный в процессе аугментации, окончательно корректируется, чтобы искаженная область не выходила за границы исходного изображения K_i . Далее формируется искаженное изображение (см. рис. 2), которое вместе с классом c_{ij} помещается в соответствующую (обучающую или тестовую) расширенную выборку




Рис. 2. Пример аугментации позиции, обозначающей дефект класса «вмятина»

Обучение искусственной нейронной сети

В отличие от обычной классификации задача поиска дефектов характеризуется наличием суперклассов («дефект», «не дефект»). Внутри суперклассов ошибка предсказания по большому счету не важна. Перепутать типы дефектов,

или не дефектные зоны не критично, в то время как пропуск дефекта, или перебраковка скажутся на технологическом процессе.

Так как ИНС при классификации лишь «предсказывает» результат с определенной вероятностью, то можно установить порог «уверенности» для определения дефекта. Перебражкой будем считать уверенное (с вероятностью выше порога) определение не дефектной позиции, как дефекта. При классификации дефектной позиции пропуском считается, классификация с вероятностью ниже порога, или классификация в суперклассе «не дефект».

Учет порога уверенности при определении дефекта введен только в оценку качества работы ИНС. В процессе обучения любая ошибка определения класса, независимо от значений порога и правильности определения суперкласса, приводит к обратному распространению.

Для проведения обучения задается размер эпохи, количество эпох, порог уверенности и размер теста. Размер эпохи определяет количество изображений, полученных путем аугментации из позиций исходной обучающей выборки, которые будут участвовать в обучении, после которого будет выполнена проверка качества обучения. Размер теста определяет количество изображений, полученных путем аугментации из позиций исходной тестовой выборки, которые будут участвовать в проверке. Расширенная обучающая выборка формируется случайным образом из всех позиций исходной выборки, то есть некоторые позиции в эпоху могут не попасть, а некоторые могут быть представлены многократно. Расширенная тестовая выборка формируется пропорционально исходной, то есть все позиции исходной тестовой выборки будут представлены в среднем равное количество раз.

Обнаружение дефектов

Для решения задачи обнаружения и локализации объектов в изображении существует множество классов алгоритмов. Среди технологий, относящихся к машинному обучению, можно выделить гистограмму направленных градиентов (Histogram of Oriented Gradients, HOG) [14], каскады признаков Хаара (Haar-like features) [15], локализацию объектов методом скользящего окна [16] и семантическую сегментацию [17]. Предложенный в работе метод обнаружения является комбинацией метода скользящего окна с постоянными размерами и классификатора на основе сверточной ИНС. Такой выбор сделан в пользу высоких требований к производительности и низким к точности определения положения дефекта.

Для поиска дефектов в произвольном изображении вначале производится нормализация всего объема данных, после чего выполняется сканирование (классификация фрагментов нормализованного изображения при помощи ИНС) с заданными шагами по вертикали и горизонтали. При обнаружении дефекта фиксируется информация о дефектной области – координаты центра и размеры проанализированной области. После завершения сканирования пересекающиеся дефектные области объединяются (см. рис. 3).




Рис. 3. Результат сканирования микрофотографии твэла, содержащей изображение вмятины. Синим цветом обозначены области, обнаруженные при сканировании. Объединенная дефектная область обозначена желтой рамкой

Следует отметить, что твэл реакторов типа БН-800 достаточно сложно устроен для внешнего осмотра. Кроме обычной поверхности оболочки и проволоки существуют особые зоны: верхняя и нижняя заглушки (см. рис. 4), сварные швы, штрих-код, пуклевка и маркировка. Почти все особые зоны могут комбинироваться с проволокой.



Рис. 4. Обнаружение царапины на нижней заглушке

Для каждой особой зоны создан класс в суперклассе «не дефект», что позволяет выделять дефекты на достаточно сложном, контрастном фоне. Тем не менее, вероятность обнаружения дефектов в особых зонах значительно ниже, что объясняется как небольшим объемом обучающих данных, так и схожестью внешних признаков особых зон с некоторыми классами дефектов. Например, технологический рельеф на нижней заглушке (рис. 4) недопустим на обычной поверхности оболочки и должен на ней идентифицироваться как набор царапин, или рисунок, а технологические вмятины в зоне пуклевки являются настолько глубокими, что делает присутствие подобного рельефа недопустимым даже в зонах со сниженными требованиями к допустимой глубине дефектов.

В связи с этим алгоритм обнаружения дефектов не ограничивается анализом одного текущего изображения, а учитывает информацию об относительном положении изображения на твэле и информацию о положении особых зон, как технологическую, так и полученную в процессе контроля.

Экспериментальные исследования

Для оценки эффективности работы алгоритма обнаружения дефектов была создана ИНС, проведена классификация имеющихся дефектов, создана обучающая выборка, содержащая более 5000 позиций, и тестовая выборка, содержащая более 1500 позиций.

ИНС классифицирует изображения по 12 классам: не дефект, вмятина, технологическая вмятина, накол, царапина, загрязнение, сдир, отпечаток, потертость, маркировка, штрих-код, заглушка нижняя.

Экспериментальная ИНС состоит из 8 слоев:

- 1) входной слой 159×159 пикселей;
- 2) свертка 5×5 , 40 признаков, шаг 2×2 , активация ReLU [18];
- 3) субдискретизация 2×2 (максимум);
- 4) свертка 5×5 , 40 признаков, шаг 2×2 , активация ReLU;
- 5) субдискретизация 2×2 (максимум);
- 6) свертка 3×3 , 40 признаков, шаг 2×2 , активация ReLU;
- 7) полносвязный 480×1024 , активация ReLU;
- 8) полносвязный 1024×12 .

Обучение производилось на графическом ускорителе NVIDIA GeForce GTX1070Ti. При размере эпохи 10000 и размере теста 6000 обучение в течение 500 эпох занимало около полутора часов.

В результате обучения при пороге уверенности обнаружения дефекта 98% средняя ошибка ИНС на тестовой выборке составляет менее 0.25%, средняя уверенность в правильном ответе превышает 99,5%.

С использованием имитаторов твэлов и без применения аугментации было сформировано множество из 1000 изображений с микродефектами (42 различных дефекта) и 10000 без дефектов. Сканирование этих изображений выполнялось с шагом равным $1/3$ от размера входного слоя, то есть 53 пикселя по обеим координатам. Если на изображении, содержащем дефект, не обнаруживалась ни одна дефектная область – засчитывался пропуск дефекта, если на бездефектных изображениях обнаруживалась дефектная область – засчитывалась перебраковка. В результате сканирования 11000 изображений было зафиксировано 24 пропуска из 1000 (2.4%) и 19 перебраковок из 10000 (0.19%).

С учетом того, что для осмотра поверхности одного твэла нужно приблизительно 2000 изображений, процент перебраковки пока достаточно высок для использования ИНС в автоматическом режиме.

Низкий процент пропуска дефектов позволяет планировать использование ИНС в составе полуавтоматической установки, где обнаружением дефектных позиций будет заниматься автомат, а окончательное решение о разбраковке твэла будет приниматься оператором.

Заключение

Разработана архитектура обучающего множества, позволяющая экономить время формирования обучающих данных при изменении конфигурации входного слоя ИНС.

Представленный алгоритм обнаружения дефектов позволяет эффективно находить дефекты, как небольшого размера, так и превышающие по площади входной слой ИНС.

Экспериментальные исследования показали высокую (более 97%) вероятность обнаружения дефектов и относительно низкий (0.19% от количества изображений) процент перебраковки. Это делает возможным использование представленной технологии в составе полуавтоматической установки, снимающей с оператора нагрузку на выполнение полного осмотра поверхности твэла и оставляющей за человеком только принятие решения о браке на основе анализа изображений обнаруженных дефектов.

Дальнейшие исследования применимости разработанного программно-алгоритмического комплекса для полной автоматизации процесса контроля требуют получения статистически большого количества изображений реальной контролируемой продукции.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Карлов Ю.К., Кулешов В.К. Комплексный контроль дефектов внешнего вида твэлов ВВЭР-1000 // Приборы. – 2013. – № 10. – С. 21–25.
2. Сысоев Е.В., Выхристюк И.А., Куликов Р.В., Поташников А.К. Система контроля механических повреждений внешней поверхности оболочки твэла реактора БН-800 // Датчики и системы. 2015. № 9-10 (196). С. 58–61.
3. Пост УКИ-7М контроля качества поверхности твэла и качества навивки проволоки реактора БН-800 [Electronic resource]. – Mode of access : <http://www.niitfa.ru/client/radiatsionnoe-priborostroenie/post-uki-7m-kontrolya-kachestva-poverkhnosti-tvela-i-kachestva-navivki-provoloki-reaktora-bn-800/> (дата обращения: 30.03.2020).
4. Удивительные возможности нейросетей 2019 года [Electronic resource]. – Mode of access : <https://habr.com/ru/post/457710/> (дата обращения: 30.03.2020).
5. Chaichulee, S.; Villarroel, M.; Jorge, J.; Arteta, C.; Green, G.; McCormick, K.; Zisserman, A.; Tarassenko, L. Multi-task convolutional neural network for patient detection and skin segmentation in continuous non-contact vital sign monitoring. In Proceedings of the 2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017), Washington, DC, USA, 30 May–3 June 2017; pp. 266–272.
6. Zeiler, M. D. and Fergus, R., 2013. Visualizing and Understanding Convolutional Networks. arXiv.org p. arXiv:1311.2901.
7. A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. In NIPS, 2012.

8. Обучение нейросети с учителем, без учителя, с подкреплением [Electronic resource]. – Mode of access : <https://neurohive.io/ru/osnovy-data-science/obuchenijs-uchitelem-bez-uchitelja-s-podkrepleniem/> (дата обращения: 30.03.2020).

9. Синтез многослойных систем распознавания образов / А. И. Галушкин. — М.: Энергия, 1974 г.

10. Gradient Descent Algorithm and Its Variants [Electronic resource]. – Mode of access : <https://towardsdatascience.com/gradient-descent-algorithm-and-its-variants-10f652806a3> (дата обращения: 30.03.2020).

11. CUDA for developers [Electronic resource]. – Mode of access : <https://developer.nvidia.com/cuda-zone> (дата обращения: 30.03.2020).

12. NVIDIA cuDNN [Electronic resource]. – Mode of access : <https://developer.nvidia.com/cudnn> (дата обращения: 30.03.2020).

13. Image Augmentation for Convolutional Neural Networks [Electronic resource]. – Mode of access : <https://medium.com/@ODSC/image-augmentation-for-convolutional-neural-networks-18319e1291c> (дата обращения: 30.03.2020).

14. Wikipedia: Histogram of oriented gradients [Electronic resource]. – Mode of access : http://en.wikipedia.org/wiki/Histogram_of_oriented_gradients (дата обращения: 30.03.2020).

15. Wikipedia: Haar-like features [Electronic resource]. – Mode of access : http://en.wikipedia.org/wiki/Haar-like_features (дата обращения: 30.03.2020).

16. Joseph Howse, Joe Minichino Learning OpenCV 3 Computer Vision with Python – Second Edition, Packt Publishing, September 2015, Packt Publishing, ISBN: 9781785289774

17. Семантическая сегментация [Electronic resource]. – Mode of access : <https://neurohive.io/ru/osnovy-data-science/semantic-segmentation/> (дата обращения: 30.03.2020).

18. Функции активации нейросети [Electronic resource]. – Mode of access : <https://neurohive.io/ru/osnovy-data-science/activation-functions/> (дата обращения: 30.03.2020).

© И. А. Выхристюк, 2020