

Диагностика нефтяных трубопроводов с помощью машинного обучения

Ю. Д. Кацер¹, В. О. Козицин²

Метод дефектоскопии на основе магнитного потока является наиболее распространенным подходом для неразрушающего контроля нефте- и газопроводов. В результате дефектоскопии получают магнитограммы, зачастую анализируемые полуавтоматизированными методами, что приводит к снижению точности и увеличению времени анализа.

В работе предложена новая архитектура CNN для автоматической классификации изображений на основе магнитограмм для диагностики нефтепроводов. В результате апробации разработанных алгоритмов на отложенной выборке была доказана высокая точность и эффективность разработанного решения.

Ключевые слова: Глубинное обучение, Машинное зрение, сверточные нейронные сети, поиск аномалий, внутритрубная диагностика нефтепроводов, обработка данных магнитного потока

1. Введение

Метод дефектоскопии на основе магнитного потока (Magnetic Flux Leakage - MFL) является наиболее распространенным подходом для неразрушающего контроля нефте- и газопроводов. Данные, полученные в процессе дефектоскопии трубопровода, в основном анализируются традиционными методами Машинного Обучения (МО). Основная задача обработки данных с дефектоскопа это классифицировать стенку трубопровода на дефектную и бездефектную. Сравнение качества работы различных методов МО для проблемы обнаружения дефектов представлено в [1]. Основная проблема этого подхода заключается в необходимости создания информативных и важных признаков на основе данных магнитограмм, которые будут использоваться в качестве входных данных для методов МО. Обычно эти диагностические признаки генерируются использованием экспертных знаний и представляют собой созданные вручную эвристики. Это накладывает ограничение на качество решения

¹Кацер Юрий Дмитриевич — аспирант сколковского института науки и технологий, e-mail: Iurii.katser@skoltech.ru.

Katser Iurii Dmitrievich — graduate student, Skolkovo Institute of Science and Technology.

²Козицин Вячеслав Олегович — аспирант сколковского института науки и технологий, e-mail: Vyacheslav.Kozitsin@skoltech.ru.

Kozitsin Vyacheslav Olegovich — graduate student, Skolkovo Institute of Science and Technology.

задачи обнаружения дефектов. Разнообразие наиболее успешных диагностических признаков представлено и подробно проанализировано в работе [2].

Глубокое обучение показало значительный прогресс и достигло невероятных результатов во многих приложениях, только за последние несколько лет. Задача классификации изображений является одним из наиболее успешных примеров применения глубокого обучения и, в частности, свёрточных нейронных сетей (CNN). Их преимуществом является возможность решать проблемы обнаружения, классификации и сегментации дефектов или сварных швов трубопроводов одновременно с автоматизированным созданием диагностических признаков. Таким образом, в данной работе исследовалось применение глубоко обучения для задач диагностики трубопроводов. В CNN используются три основных типа слоев: convolutional (сверточный), pooling и fully-connected layer (полносвязный линейный) слой. Сверточные слои предназначены для извлечения признаков из входных данных путем применения фильтров к различным областям изображений. После нескольких сверточных слоев, обычно применяются pooling слои, чтобы уменьшить размер получившегося тензора. Полносвязные слои - это, как правило, последние слои CNN, обладающие схожей структурой по сравнению с традиционными нейронными сетями прямого распространения.

2. Архитектура разработанной CNN

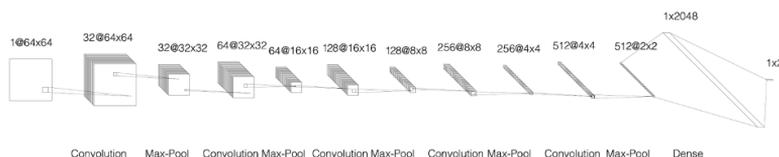


Рис. 1. Архитектура разработанной CNN

Предлагаемая архитектура (рис. 1) состоит из 5 сверточных слоев. За каждым сверточным слоем следуют BatchNormalization и Dropout слои последовательно (не показано на рисунке). Все сверточные слои имеют одинаковый размер ядра - 5 x 5. Все слои MaxPooling имеют одинаковый размер ядра - 2 x 2 с шагом - 2.

3. Данные

Данные собраны при обследовании трубы диаметром 219 мм. Выборка данных магнитного потока предоставляет информацию об одном запус-

ке дефектоскопа. Выборка данных имеет 64 признака, собранных в виде вектора для каждого шага движения дефектоскопа внутри трубы. Выборка данных содержит 4470704 точки, представляющих участок трубопровода длиной 15162,85 метра. Значения выборки варьируются от 0 до 4095 единиц. В выборке зафиксировано наличие 745 дефектов разных типов и 1462 сварных шва, 34 из которых дефектные. Прилагаемый к выборке данных технический отчет содержит информацию о местоположении сварных швов и дефектов, типах дефектов, размерах и других соответствующих характеристиках.

Таблица 1. Характеристики используемых данных

Параметр	Значение
Диаметр трубопровода, мм	219
Длина трубопровода, м	15162,85
Количество точек	4470704
Количество признаков	64
Минимальное значение в выборке	0
Максимальное значение в выборке	4095
Количество дефектов	745
Количество швов (с дефектом)	1462 (34)

4. Результаты

В конечном итоге, в данной работе предложена новая архитектура CNN для классификации изображений на основе магнитограмм. Кроме того, представлены существующие архитектуры, которые достигают лучших результатов на сегодняшний день в задачах классификации данных магнитограмм и рентгеновского излучения при анализе трубопроводов. В результате апробации разработанных алгоритмов на отложенной выборке была доказана эффективность разработанного решения:

- точность обнаружения дефектов – более 90%;
- точность многоклассовой классификации – 95% .

Результаты экспериментов доказывают, что все части процесса диагностики нефтепровода могут быть полностью автоматизированы с высоким качеством.

Список литературы

- [1] Khodayari-Rostamabad A., Reilly J., Nikolova N., Hare J., Pasha S., “Machine learning techniques for the analysis of magnetic flux leakage images in pipeline inspection”, *IEEE Transactions on Magnetism*, **45:8** (2009), 3073–3084.
- [2] Д. А. Слесарев, *Развитие магнитного метода неразрушающего контроля за счет автоматизации обработки данных и оптимизации алгоритмов обнаружения дефектов*, дисс. ... докт. техн. наук, Москва, 2017, 43 pp.

Machine Learning Based Oil Pipeline Diagnostics

Katser I.D., Kozitsin V.O.

The magnetic flux leakage (MFL) method is the most common approach for non-destructive testing of oil and gas pipelines. As a result of MFL detection, magnetograms are obtained, often analyzed by semi-automated methods, which leads to a decrease in accuracy and an increase in analysis time.

The paper proposes a new CNN architecture for automatic image classification based on magnetograms for oil pipeline diagnostics. As a result of testing the developed algorithms on a deferred sample, the high accuracy and efficiency of the developed solution were proved.

Keywords: Deep learning, Computer vision, Convolutional neural networks, Anomaly detection, Oil pipeline diagnostics, Magnetic Flux Leakage data processing

References

- [1] Khodayari-Rostamabad A., Reilly J., Nikolova N., Hare J., Pasha S., “Machine learning techniques for the analysis of magnetic flux leakage images in pipeline inspection”, *IEEE Transactions on Magnetism*, **45:8** (2009), 3073–3084
- [2] Slesarev D.A., *Development of the magnetic method of non-destructive testing due to automation of data processing and optimization of defect detection algorithms*, Doctor of Science in Technology, Moscow, 2017 (In Russian), 43 pp.