

Методы генерации синтетических данных для прогнозирования распределения дефектов в энергетических установках с использованием глубокого обучения

А.Е. Александров, Н.С. Поляков
Московский технический университет связи и информатики

Аннотация: В последние годы безопасная эксплуатация объектов энергетики чаще обеспечивается системами неразрушающего контроля, имеющих вероятностный характер. В статье рассматривается способ прогнозирования и оценки количества пропущенных дефектов, решая обратную задачу. Проводится детальный анализ косвенных проявлений и прогнозирование косвенного параметра с использованием библиотеки глубокого обучения – Keras, определяющих количественные характеристики исследуемого объекта. Результаты исследования показывают обнадеживающую точность прогнозирования с исправимыми признаками переобучения модели.

Ключевые слова: неразрушающий контроль, дефект, кривые распределения вероятности обнаружения дефектов, синтетические данные для глубокого обучения, регрессионное прогнозирование, Keras, структурные и семантические признаки, нелинейные зависимости.

Введение

Безопасная эксплуатация объектов энергетики обеспечивается различными средствами. Одним из наиболее важных средств обеспечения безопасной эксплуатации являются диагностические методы, позволяющие обнаруживать различные дефекты, и не нарушающие целостности работающих конструкций. Системы, использующие такие диагностические методы, получили название систем неразрушающего контроля. Принцип работы этих систем основан на воздействии сигнала на исследуемую конструкцию и последующей обработке его с целью определения – найден дефект или нет [1, 2].

Эффективность работы используемых систем контроля имеет вероятностный характер. Поэтому после проведения контроля часть дефектов остается в конструкции необнаруженной. Количественная оценка пропущенных дефектов позволяет оценить степень надежности проведенного

контроля и принять адекватные меры в части дальнейшей эксплуатации объекта или его ремонта.

Исходными данными для анализа и восстановления неизвестных распределений дефектов являются данные по дефектности, полученные в результате обнаружения и извлечения из диагностируемой конструкции. Поэтому в случае ложноположительных результатов эти данные не учитываются при анализе, т.е. ошибки, связанные с ложноположительными результатами в этом случае исключаются. Основную опасность для дальнейшей эксплуатации конструкции представляют именно пропущенные дефекты, которые и являются предметом данного исследования.

Для прогнозирования и оценки количества пропущенных дефектов приходится решать обратную задачу, т.е. имея число обнаруженных дефектов, надо найти число пропущенных и действительных дефектов, которые были образованы в процессе эксплуатации исследуемой конструкции. Если известны множества как обнаруженных, так и действительных дефектов, то для нахождения соответствия между этими множествами могут быть использованы нейронные сети и машинное обучение.

Однако отличительной особенностью алгоритмов глубокого обучения является востребованность больших массивов, размеченных данных для их обучения. В настоящий момент данные об обнаруженных дефектах являются ограниченными [3, 4], а данные по распределению и числу действительных дефектов, могут отсутствовать. Поэтому эти ограничения существенно затрудняют использование алгоритмов нейронного и машинного обучения в автоматизированных системах управления технологическими процессами для обеспечения безопасной эксплуатации объектов энергетики.

В данной работе рассматривается методика генерации синтетических данных как для обнаруженных, так и для действительных дефектов, которые могут быть использованы для решения исходной обратной задачи.

Организация исследования

Поставленная выше задача предполагает определение количественных характеристик в виде действительного распределения дефектов по результатам полученных обнаруженных дефектов. Данный класс задач можно рассматривать как обратные задачи, в которых количественные характеристики исследуемого явления определяются по результатам измерений косвенных проявлений. Математическое описание данной задачи может быть сделано в следующем виде:

$$Az = u, \quad (1)$$

где A – математический оператор, преобразующий действительное распределение дефектов в обнаруженное; u – известное распределение обнаруженных дефектов, полученное по результатам проверки системой неразрушающего контроля; z – толщина образца; x – текущая координата.

Учитывая вероятностный характер систем контроля при обнаружении дефектов, воздействие оператора в формуле (1), преобразующего действительное распределение в обнаруженное, заключается в умножении действительного распределения на функцию $f_r(a)$, которая определяет вероятность обнаружения дефекта заданного размера – a . Данная зависимость является количественной мерой надежности проведенного контроля. В литературе данная функциональная зависимость известна как функция обнаружения дефектов - $PoD_{SC}(a)$ – Probability of Detection) [5, 6], где нижний индекс SC относится к конкретной системе контроля.

Функциональное описание $f_r(a)$ действительного распределения дефектов должно соответствовать конкретному виду дефекта -

поверхностные, объемные, поры, включения, трещины и т.д. [4]. Для большинства видов дефектов – число дефектов увеличивается с уменьшением размерного масштаба. В этом случае, для описания действительного распределения может быть использован экспоненциальный закон [7, 8]:

$$f_r(a) = \frac{\exp(-a/\lambda)}{\int_0^S \exp(-a/\lambda) da} \quad (2)$$

где a – размер дефекта; λ – параметр действительного распределения дефектов; S – характерный размер исследуемой области, толщина стенки трубы.

Используя функциональную зависимость для обнаружения дефектов - $PoD_{SC}(a)$ и для действительного распределения формулу (2), получим следующую формулу для плотности распределения обнаруженных дефектов - $f_d(a)$:

$$f_d(a) = \frac{\exp(-a/\lambda) \cdot PoD_{SC}(a)}{\int_{a_0}^S \exp(-a/\lambda) \cdot PoD_{SC}(a) da} \quad (3)$$

где a_0 – коэффициент чувствительности исходной системы контроля (минимальный размер дефекта, обнаруживаемый исходной системой – SC).

Для кривой $PoD_{SC}(a)$ была выбрана следующая функциональная форма [9]:

$$POD_{SC}(a) = 1 - \exp(-r \cdot (a - a_0)) \quad (4)$$

где r – коэффициент достоверности исходной системы контроля – SC .

Подставляя в формулу (3) вместо значения $PoD_{SC}(a)$ функциональную формулу (4), получим для распределения обнаруженных дефектов следующую зависимость

$$f_a(a) = \frac{\exp(-a/\lambda) \cdot (1 - \exp(-r \cdot (a - a_0)))}{\int_{a_0}^s \exp(-a/\lambda) \cdot (1 - \exp(-r \cdot (a - a_0))) da}, \quad (5)$$

Формулы (2) и (5) были использованы для обучения нейронных сетей. Обученная таким образом, нейронная сеть дает возможность восстанавливать неизвестные параметры λ и r для выборки экспериментально обнаруженных дефектов.

Архитектура нейронной сети

На основе полученных формул – (2,5) был написан код генерации случайной последовательности для действительных и обнаруженных дефектов. Код помещает в созданный файл сгенерированные выборки обнаруженных дефектов и соответствующие им параметры – λ и значения длин выборок. Иначе говоря, он сохраняет параметр, результат и класс результата в базу данных.

Для реализации обучения модели на основе сгенерированных данных выбрана высокоуровневая библиотека глубокого обучения – Keras, основанная на низкоуровневой библиотеке – TensorFlow. Ее использование обусловлено удобным способом определения и тренировки моделей глубокого обучения. Для нее определен один из базовых оптимизаторов – Adam и определена функция потерь среднеквадратичной ошибки – MSE, подходящая для задачи регрессии, также для оценки обучения дополнительно определена функция средней абсолютной ошибки – MAE, не влияющая на веса.

Общая архитектурная схема нейронной сети с 25 слоями приведена на рис.1.

Сгенерированные выборки обнаруженных дефектов и значения длин выборок из собранной базы предварительно классифицируются по соответствующим им параметрам – λ , и нормализуются с помощью

обучающегося масштабатора, инструмента – StandartScaler из библиотеки машинного обучения – Scikit-Learn.

Входной слой представлен в стандартной форме записи тензора – (N, L, C) , где N – выборки обнаруженных дефектов, L – длины выборок, C – номер характеристической карты (канал). Параметры – λ выступают целевыми метками модели, которые нейронная сеть стремится предсказать.

Используется глубокий каскад из трех сверточных слоев – Conv1D [10], каждый из которых снабжен функцией активации – ReLU, механизмом нормализации – BatchNormalization, слоем стохастической регуляризации – Dropout.

Формирование характеристических карт с признаками слоями – Conv1D [11] воспроизводится с параметром количества ядер равным трем, оставаясь оптимальным решением по скорости свертки и извлечению глубоких и комплексных признаков. Постепенное увеличение фильтров в каскаде приводит к нахождению более сложных паттернов. Функция активации – ReLU не допускает появление отрицательных значений признаков в ходе обучения [11].

Продолжение каскада слоем Conv1D с количеством 2048 фильтров оказалось неприемлемым из-за чрезвычайно высоких требований к ресурсам и длительного времени обработки. Отсюда обусловлено единожды использование слоя – MaxPooling1D, который снижает размерность признаков окном пулинга в два раза, т.е. $L / 2$. При этом теряется чувствительность к точному местоположению признаков, тем самым значимее становится относительное положение или выявление определенных паттернов, что приспособливает модель к естественным особенностям реальных данных.

Если ранний каскад – Conv1D находил структурные признаки [10], то после пулинга последующий слой – Conv1D с количеством фильтров 2048

создает представление семантических признаков. И следующий такой же второй слой углубляет представление, что сопоставимо с нахождением нелинейной зависимости между семантическими признаками.

Полносвязный слой – Dense с 1024 нейронами и активацией – ReLU принимает от слоя – Flatten тензор – $(N, L \times C)$, где все признаки из всех позиций и каналов становятся равноправными входами. Тензор задействован в формуле аффинного преобразования с последующей нелинейной активацией. Каждый нейрон вычисляет свою комбинацию признаков путем изменения набора весов с помощью градиентного спуска.

Затем используется второй полносвязный слой – Dense с 512 нейронами, для уменьшения размерности, и функцией – ReLU. Обобщение позволяет после слоя с большим количеством нейронов исключить появление линейных нейронов.

Выходной слой – Dense с 1 нейроном объединяет 512 признаков в прогнозируемое значение параметра – λ .

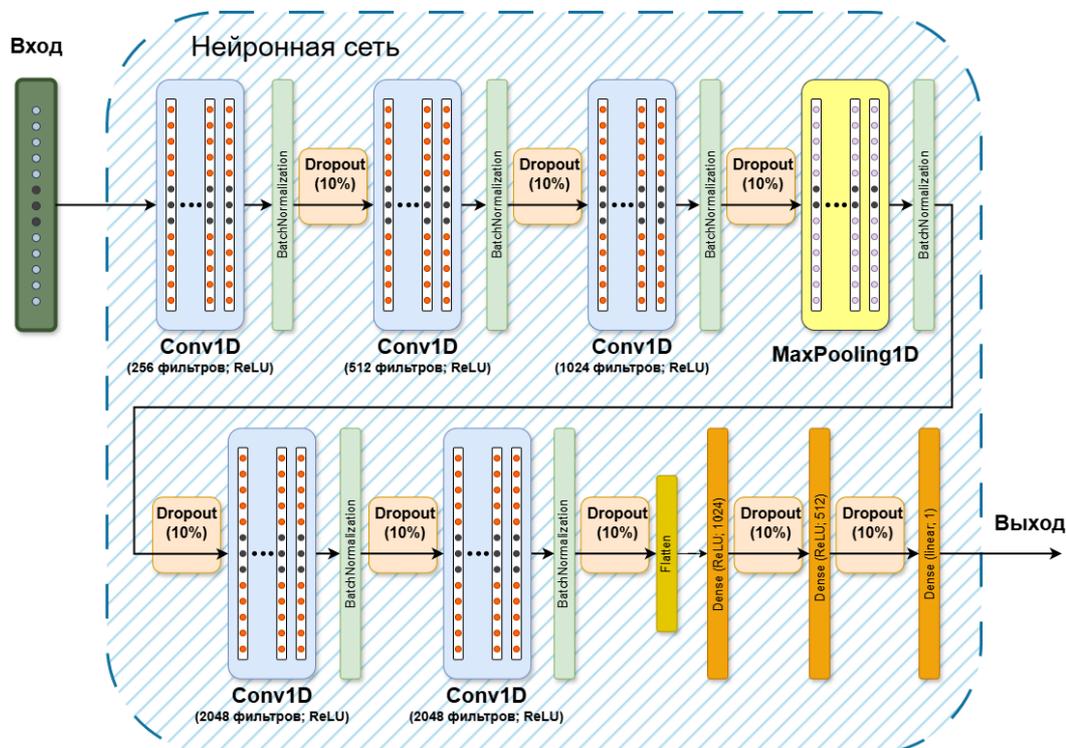


Рис. 1. – Общая архитектурная схема нейронной сети

Указанное перед запуском обучения значение настройки – patience влияет на остановку обучения, если количество последних эпох, не уменьшавших метрику среднеквадратичной ошибки – MSE, выровняется с ним, то произойдет остановка обучения с сохранением сформированного файла обученной модели прогнозирования параметра – λ по выборке обнаруженных дефектов с заведомо выбранной длины выборки. Также сохраняется файл обученного масштабатора. Его сохранение позволит знакомым образом для модели нормализовать выборку на входе, а после восстановить спрогнозированную – λ .

Результаты экспериментов

Для оценки обученной модели нейронной сети проведены два эксперимента генерации двух разных баз данных с количеством выборок 182000 каждая. Диапазон параметров – λ изменялся от 1 до 5.5, и с шагом 0.05 производилась генерация 2000 выборок при выбранном значении длины выборки равное 15. Параметры размеров обнаруженных дефектов находились в диапазоне от $a_0 = 0.5$ до $a = 20$ миллиметров. Различие баз данных определяется значениями параметра r , которые были приняты – 0.1 и 0.3.

Выбор необходимого объема для базы данных сделан произвольно. Распределены 145600 выборок на валидацию для показательного отслеживания метрик после каждой эпохи без влияния на веса и 36400 выборок на обучение.

Оценкой качества моделей выступают метрики – MSE и MAE.

Метрика среднеквадратичного отклонения – MSE показывает усредненное по всему набору данных значение квадрата разности между спрогнозированными значениями – λ и истинными значениями параметра – λ . Метрика – MSE, в виду присутствия возведения ошибки в квадрат, более

чувствительна к большим выбросам, чем метрика – MAE. Потому была выбрана функция потерь – MSE, чаще подвигаемая на изменение весов.

Метрика средней абсолютной ошибки – MAE демонстрирует усредненное по всему набору данных значение разности между абсолютными спрогнозированными значениями – λ и абсолютными истинными значениями параметра – λ .

В ходе первого эксперимента с использованием базы данных с r равным 0.1, результаты которого показаны в таблице 1, по соотношениям метрик стало ясно, что

- MSE на валидации приблизительно в 1.1 раза больше, чем MSE на обучении;
- MAE на валидации больше обучающей – MAE в 1.039 раза.

Уже во втором эксперименте при использовании базы данных с r равным 0.3, результаты которого показаны в таблице 1, по соотношениям метрик выяснено, что:

- MSE на валидации приблизительно в 1.2 раза больше, чем MSE на обучении;
- MAE на валидации больше обучающей – MAE в 1.079 раз.

Во всех случаях это указывает на переобучение, вызванное появлением линейной зависимости. Способ решения проблемы, вероятно, заключается в увеличении объема данных.

Большое значение patience равное 50 было выставлено для сбора информации полученных потерь по эпохам, что в дальнейшем позволит выставлять значение, обеспечивающее приемлемые потери [12].

Графики обучающих и валидационных потерь по эпохам и метрикам – MSE и MAE для различных значений $r = 0.1$ и $r = 0.3$, где наилучшие эпохи находятся от последней эпохи на расстоянии параметра настройки – patience равное 50, приведены на рисунках 2-5.

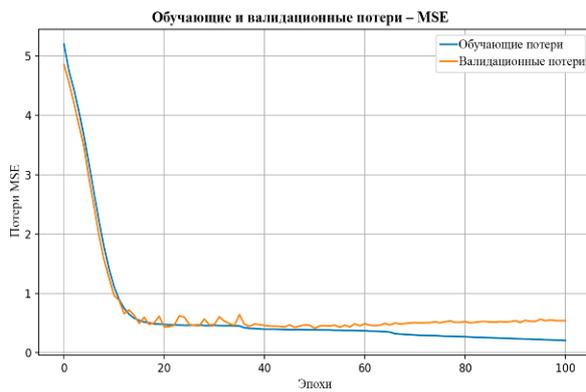


Рис. 2. – График обучающих потерь (MSE) и валидационных потерь (MSE) при $r = 0.1$

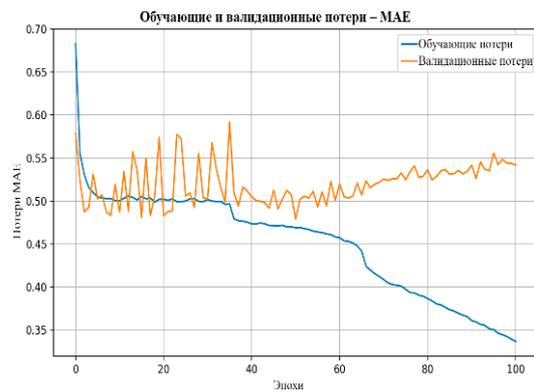


Рис. 3. – График обучающих потерь (MAE) и валидационных потерь (MAE) при $r = 0.1$

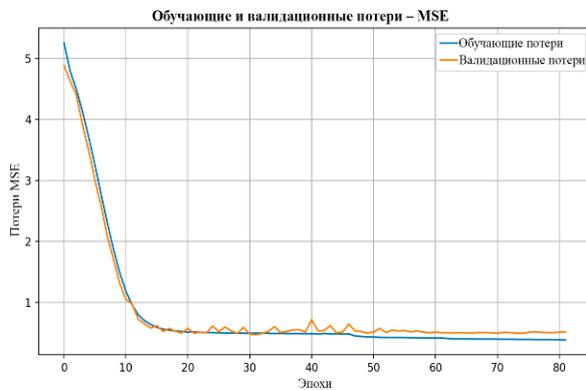


Рис. 4. – График обучающих потерь (MSE) и валидационных потерь (MSE) при $r = 0.3$

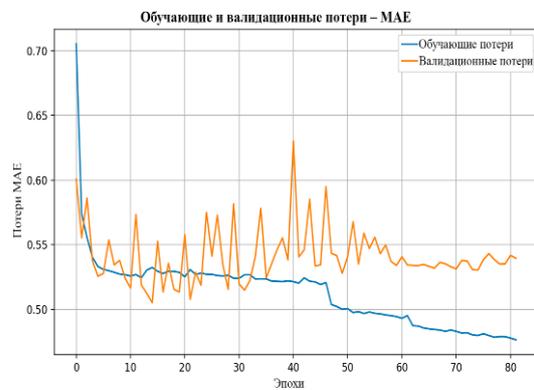


Рис. 5. – График обучающих потерь (MAE) и валидационных потерь (MAE) при $r = 0.3$

Результаты значений метрик – MSE и MAE по наилучшей эпохе по первой и второй баз данных отображены в таблице 1.

Таблица № 1

Оценочные показатели двух экспериментов по лучшим эпохам

Оценочные показатели	При $r = 0.1$	При $r = 0.3$
Количество эпох	50	32
$MSE_{\text{Обучающие}}$	0.4861	0.3827
$MSE_{\text{Валидационные}}$	0.5360	0.4594
$MAE_{\text{Обучающие}}$	0.5203	0.4700
$MAE_{\text{Валидационные}}$	0.5406	0.5075

Надежность работы модели определена диаграммами рассеивания доверительных интервалов и гистограммами распределения ошибок, построенные на валидационных выборках, отображены на рисунках 6–9.

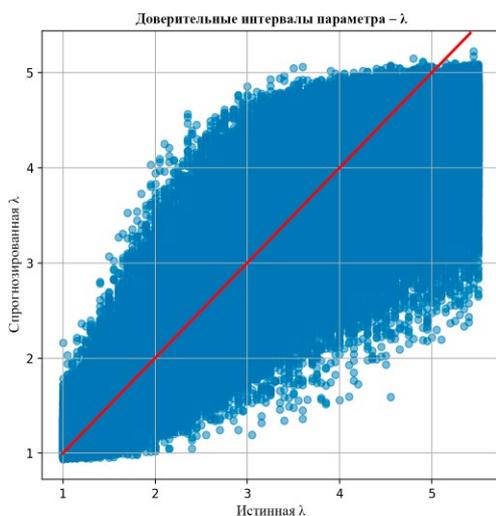


Рис. 6. – Диаграмма рассеивания доверительных интервалов при $r = 0.1$

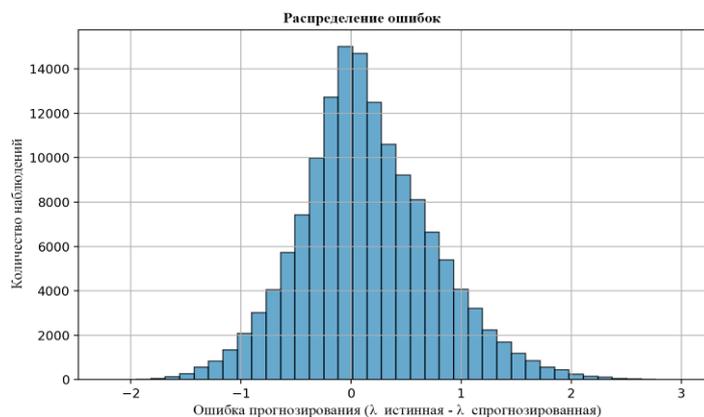


Рис. 7. – Гистограмма распределения ошибок при $r = 0.1$

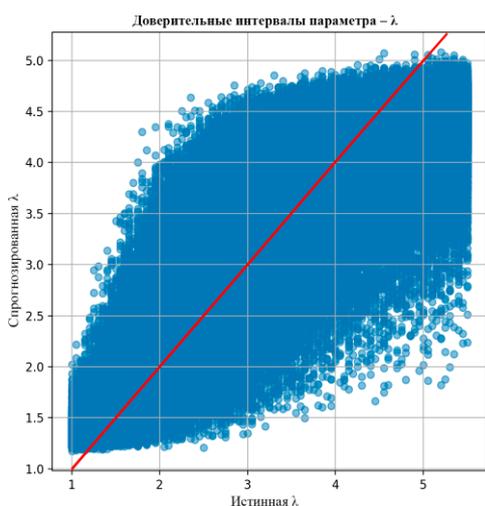


Рис. 8. – Диаграмма рассеивания доверительных интервалов при $r = 0.3$

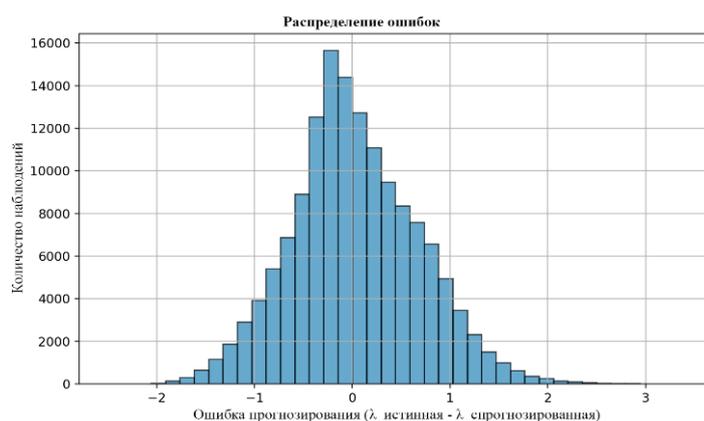


Рис. 9. – Гистограмма распределения ошибок при $r = 0.3$

Пирамидальная форма гистограмм распределения ошибок указывают на хорошую точность моделей. По мере отклонения от 0 количество наблюдений уменьшается. Но требуется сужение по доверительным интервалам, которые показали недопустимо большой разброс значений.

Заключение (выводы)

Предварительно проведенные вычислительные эксперименты дали основания считать, предложенную методику перспективной в части

восстановления неизвестного параметра λ на основе случайных выборок обнаруженных дефектов с использованием разработанных алгоритмов (рис. 6-9). Обученные модели приобрели необходимую способность прогнозировать, это видно по гистограмме распределения ошибок, но имеют явные признаки переобучения – плохая сходимость обучающих и валидационных метрик, а также широкий доверительный интервал.

Таким образом, в дальнейшем следует увеличить количество выборок, подаваемых при обучении модели нейронной сети. Увеличенное количество выборок приведет к созданию большего количества нелинейных зависимостей. Нелинейные зависимости откинут признаки переобучения, и, следует ожидать, что будет достигнут желаемый результат.

Литература

1. Лагунова Ю.А., Хорошавин С.А., Набиуллин Р.Ш., Калянов А.Е. Анализ металлоконструкций стрелы карьерного экскаватора методом неразрушающего контроля // Транспортное, горное и строительное машиностроение: наука и производство. 2022. №15. С. 115-123.

2. Литвинова Т.А., Могилевский Д.В., Мецлер А.А., Егоров С.Н., Подрезов Н.Н. Технология ультразвукового контроля технологических трубопроводов атомного реактора // Инженерный вестник Дона, 2014, №1. URL: ivdon.ru/ru/magazine/archive/n1y2014/2240.

3. Boikov A., Payor V., Savelev R., Kolesnikov A. Synthetic Data Generation for Steel Defect Detection and Classification Using Deep Learning, Symmetry. St. Petersburg Mining University and M. Auezov South Kazakhstan University. 2021. doi: 10.3390/sym13071176.

4. Fulir J., Bosnar L., Hagen H., Gospodnetic P. Synthetic Data for Defect Segmentation on Complex Metal Surfaces. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2023. Pp. 4424-4434. doi: 10.1109/CVPRW59228.2023.00465.

5. Berens A. P. Probability of Detection (POD) Analysis for the Advanced Retirement for Cause (RFC) Engine Structural Integrity Program (ENSIP) Nondestructive Evaluation (NDE) System-Volume. University of Dayton Research Institute. 2000. V. 1. 88 p.

6. Gandossi L., Annis C. Probability of Detection Curves: Statistical Best-Practices ENIQ Report. Luxembourg: Publications Office of the European Union. 2010. V. 41. 8 p.

7. Фролов К.В. Анализ риска и проблем безопасности. В 4 –х частях // Ч.1. Основы анализа и регулирования безопасности. Москва: МГФ «Знание». 2006. С. 640.

8. Волченков В.Н. Вероятность и достоверность оценки качества продукции металлопродукции. Москва: «Металлургия». 1979. С. 88.

9. Александров А.Е. Оценка достоверности результатов контроля металла на основе альтернативного метода // Информационные технологии. 2018. Том 24. №8. С. 529-537.

10. Cantero-Chinchilla S., Wilcox P. D., Croxford, A. J. Deep learning in automated ultrasonic NDE – Developments, axioms and opportunities. NDT and E International. 2022. doi: 10.1016/j.ndteint.2022.102703.

11. Qazi, E. U. H., Almorjan, A., Zia, T. A One-Dimensional Convolutional Neural Network (1D-CNN) Based Deep Learning System for Network Intrusion Detection. Applied Sciences. 2022. Doi: 10.3390/app12167986.

12. Пучков Е.В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети. Инженерный вестник Дона. 2013. №4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135.

References

1. Lagunova Ju.A., Horoshavin S.A., Nabiullin R.Sh., Kaljanov A.E. Transport, mining and construction engineering: science and production. 2022. №15. Pp. 115-123.

2. Litvinova T.A., Mogilevskij D.V., Mecler A.A., Egorov S.N., Podrezov N.N. Inzhenernyj vestnik Dona. 2014. №1. URL: ivdon.ru/ru/magazine/archive/n1y2014/2240.

3. Boikov A., Payor V., Savelev R., Kolesnikov A. Synthetic Data Generation for Steel Defect Detection and Classification Using Deep Learning, Symmetry. St. Petersburg Mining University and M. Auezov South Kazakhstan University. 2021. doi: 10.3390/sym13071176.

4. Fulir J., Bosnar L., Hagen H., Gospodnetic P. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2023. Pp. 4424-4434. doi: 10.1109/CVPRW59228.2023.00465.

5. Berens A. P. Probability of Detection (POD) Analysis for the Advanced Retirement for Cause (RFC)/Engine Structural Integrity Program (ENSIP) Nondestructive Evaluation (NDE) System-Volume. University of Dayton Research Institute. 2000. V. 1. 88 p.

6. Gandossi L., Annis C. Probability of Detection Curves: Statistical Best-Practices ENIQ Report. Luxembourg: Publications Office of the European Union. 2010. V. 41. 8 p.

7. Frolov K.V. Analiz riska i problem bezopasnosti. V 4 –h chastjah. Ch.1. Osnovy analiza i regulirovanija bezopasnosti [Risk Analysis and Safety Issues. In 4 parts. Part 1. Fundamentals of Safety Analysis and Regulation]. Moskva: MGF «Znanie». 2006. 640 p.

8. Volchenkov V.N. Veroyatnost' i dostovernost' ocenki kachestva produkcii metalloprodukcii [Probability and Reliability in Quality Assessment of Metallurgical Products]. Moskva: «Metallurgija». 1979. 88 p.

9. Aleksandrov A.E. Informacionnye tehnologii. 2018. V. 24. №8. Pp. 529-537.

10. Cantero-Chinchilla S., Wilcox P. D., Croxford, A. J. NDT and E International. 2022. doi: 10.1016/j.ndteint.2022.102703.



11. Qazi, E. U. H., Almorjan, A., Zia, T. Applied Sciences. 2022. doi: 10.3390/app12167986.

12. Puchkov E.V. Inzhenernyj vestnik Dona. 2013. №4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135.

Авторы согласны на обработку и хранение персональных данных.

Дата поступления: 9.01.2026

Дата публикации: 24.02.2026