

*Шаповалова Елена Анатольевна,
доцент, кандидат технических наук
доцент кафедры «Техносферная безопасность»
Тюменский индустриальный университет
Россия, г. Тюмень*

*Щербаков Иван Валерьевич,
студент магистратуры,
2 курс, факультет «Безопасность технологических процессов и
производств»*

*Институт сервиса и отраслевого управления
Тюменский индустриальный университет
Россия, г. Тюмень*

*Борисенко Алина Николаевна,
студент магистратуры,
2 курс, факультет «Безопасность технологических процессов и
производств»*

*Институт сервиса и отраслевого управления
Тюменский индустриальный университет
Россия, г. Тюмень*

ПРИМЕНЕНИЕ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АВТОМАТИЧЕСКОЙ КЛАССИФИКАЦИИ ДЕФЕКТОВ СВАРНЫХ ШВОВ ПО РАДИОГРАФИЧЕСКИМ СНИМКАМ

Аннотация: В статье затронута проблема дефектов сварных швов – до 70% аварий. Ограничения традиционного радиографического контроля (субъективность, трудоёмкость). Предлагается метод классификации на основе свёрточной нейронной сети (СНН). Описан датасет (75 снимков, 2

класса), предобработка, архитектура сети (три свёрточных слоя + dropout). Полученный результат: точность 94%, чувствительность 100%, специфичность 87.5%, матрица ошибок, доверительный интервал 95% для точности. Показана визуализация Grad-CAM. Общий вывод: метод эффективен для принятия решений дефектоскопистом и может быть положен в основу прикладного программного обеспечения.

Ключевые слова: свёрточные нейронные сети, радиографический контроль, дефекты сварных швов, классификация изображений, Grad-CAM, промышленная безопасность.

Abstract: This article addresses the issue of weld defects, which account for up to 70% of failures. It discusses the limitations of traditional radiographic testing (subjectivity, labor intensity). A classification method based on a convolutional neural network (CNN) is proposed. The dataset (75 images, 2 classes), preprocessing, and network architecture (three convolutional layers + dropout) are described. Results obtained: accuracy 94%, sensitivity 100%, specificity 87.5%, error matrix, 95% confidence interval for accuracy. Grad-CAM visualization is shown. General conclusion: the method is effective for decision-making by a flaw detection specialist and can serve as the basis for applied software.

Keywords: convolutional neural networks, radiographic testing, weld defects, image classification, Grad-CAM, industrial safety.

Введение: Трубопроводный транспорт является ключевым элементом инфраструктуры нефтегазовой отрасли. Однако, несмотря на строгие нормы контроля, дефекты сварных соединений остаются причиной до 70% аварий на трубопроводах [9]. Традиционный радиографический метод контроля требует значительных временных затрат (3–5 минут на один снимок) и подвержен человеческому фактору – усталость дефектоскописта и субъективность оценки снижают достоверность выявления дефектов [8].

Современное развитие методов искусственного интеллекта, в частности свёрточных нейронных сетей (СНН), открывает возможности для автоматизации задач анализа изображений [1, 3]. СНН успешно применяются для классификации и сегментации объектов на медицинских снимках, в дефектоскопии металлоконструкций и других областях [2, 4, 5]. Однако применительно к радиографическому контролю сварных швов промышленных трубопроводов разработки немногочисленны и требуют больших размеченных датасетов, что не всегда выполнимо.

В настоящей работе предлагается архитектура свёрточной нейронной сети для бинарной классификации (дефект / качественный шов) на ограниченном датасете из 75 радиографических снимков. Используются методы аугментации данных для повышения обобщающей способности [7], а также алгоритм Grad-CAM для интерпретации решений сети. Цель – достичь высокой точности (не менее 90%) и чувствительности (обнаружение всех дефектов), что позволит использовать систему в качестве «второго мнения» для дефектоскописта.

Используемые материалы и методы

Для проведения исследования использовались радиографические снимки сварных соединений из открытого датасета GDXray Welds Dataset, а также изображения, предоставленные центральной испытательной лабораторией АО «ГМС Нефтемаш». Общий объём выборки составил 75 изображений, из которых 38 отнесены к классу «дефект» (поры, трещины, непровары, шлаковые включения), а 37 – к классу «годный» (качественный сварной шов без видимых дефектов). Классификация выполнена в соответствии с ГОСТ 30242–97 [8]. Ниже, на рисунке 1 приведён пример снимка с дефектами.




Рисунок 1. Сварной шов с примерами различных дефектов

Все изображения приведены к единому размеру 128×128 пикселей и нормализованы путём деления значений пикселей на 255 (приведение к диапазону $[0,1]$). Для увеличения разнообразия обучающей выборки и предотвращения переобучения применена аугментация: случайные повороты в диапазоне $\pm 20^\circ$, сдвиги по ширине и высоте на 20%, масштабирование и горизонтальное отражение. Данные разделены на обучающую (80%, 57 снимков) и валидационную (20%, 18 снимков) выборки.

Разработана свёрточная нейронная сеть последовательной архитектуры (таблица 2). Сеть включает три свёрточных слоя (Conv2D) с функцией активации ReLU, каждый из которых сопровождается слоем подвыборки (MaxPooling2D) для уменьшения размерности. Далее следуют слой выпрямления (Flatten), полносвязный слой (Dense) с 64 нейронами и активацией ReLU, слой регуляризации Dropout с коэффициентом 0,5 для снижения переобучения и выходной слой (Dense) с 2 нейронами и активацией softmax для бинарной классификации. Общее количество обучаемых параметров – 859 330. В таблице 1 представлена архитектура нейронной сети.

Таблица 1.

Архитектура свёрточной нейронной сети

№ слоя	Тип слоя	Параметры	Число параметров
1	Conv2D	32 фильтра 3×3 , ReLU	896
2	MaxPooling2D	2×2	0
3	Conv2D	64 фильтра 3×3 , ReLU	18 496
4	MaxPooling2D	2×2	0
5	Conv2D	64 фильтра 3×3 , ReLU	36 928
6	MaxPooling2D	2×2	0

7	Flatten	–	0
8	Dense	64 нейрона, ReLU	802 880
9	Dropout	0,5	0
10	Dense	2 нейрона, softmax	130

Модель компилирована с оптимизатором Adam, функцией потерь categorical_crossentropy и метрикой accuracy. Обучение проведено в течение 15 эпох с размером батча 8. Аугментация применялась только к обучающей выборке; валидационная выборка не аугментировалась.

Для оценки качества модели использовались следующие метрики: точность (accuracy), чувствительность (sensitivity, recall для класса «дефект»), специфичность (specificity, recall для класса «годный»). Построена матрица ошибок. Для оценки статистической значимости показателя точности рассчитан 95% доверительный интервал по методу Клоппера–Пирсона.

Для интерпретации решений нейронной сети применены два метода: тепловые карты активаций (Grad-CAM), показывающие области снимка, наиболее значимые для классификации, и простая визуализация цветной рамкой (красная – дефект, зелёная – годный).

Результаты работы

С вероятностью 95% истинная точность модели на генеральной совокупности радиографических снимков лежит в диапазоне от 71,6% до 99,8%. На рисунке 2 показан результат обучения модели




Рисунок 2. Результат обучения модели

На рисунке 3 приведён пример работы тепловой карты Grad-CAM. Красным цветом выделены области, которые нейронная сеть сочла наиболее значимыми для принятия решения о дефекте.




Рисунок 3. Тепловая карта активации Grad-CAM

На рисунке 4 показан результат простой визуализации с цветной рамкой (красная – дефект, зелёная – годный).




Рисунок 4. Визуализация работы свёрточной нейронной сети

Разработанная модель обеспечивает высокую точность (94,4%) и, что наиболее важно для безопасности, 100% чувствительность – ни один дефектный сварной шов не был пропущен. Это позволяет рекомендовать систему для использования в качестве инструмента поддержки принятия решений («второго мнения») для дефектоскописта.

Заключение

В данной работе предложена и экспериментально исследована архитектура свёрточной нейронной сети для автоматической классификации дефектов сварных швов по радиографическим снимкам. На ограниченном датасете (75 изображений) модель достигла точности 94,4%, чувствительности 100% и специфичности 87,5%. Отсутствие ложноотрицательных результатов (FN=0) подтверждает способность системы не пропускать ни одного

дефектного сварного соединения, что критически важно для задач промышленной безопасности.

Разработанная модель может быть использована в качестве инструмента поддержки принятия решений («второго мнения») для дефектоскописта, позволяя снизить влияние человеческого фактора и повысить надёжность радиографического контроля. Применение методов визуализации (Grad-CAM) обеспечивает интерпретируемость результатов, что повышает доверие специалистов к автоматизированной системе.

Дальнейшие направления исследований включают расширение датасета, переход к задаче семантической сегментации для точной локализации дефектов, использование трансферного обучения (EfficientNet, ResNet), а также создание прикладного программного обеспечения для промышленного внедрения.

Список литературы:

1. Денисенко А. А. Решение задачи бинарной классификации при помощи сверточных нейронных сетей с использованием фреймворка Tensorflow // Технические науки: проблемы и решения: сборник статей по материалам XX международной научно–практической конференции. СПб.: Свое издательство, 2019. С. 1–4.
2. Клехо Д. Ю., Карелина Е. Б., Батырев Ю. П. Использование технологии сверточных нейронных сетей в сегментации объектов изображения // Лесной вестник / Forestry Bulletin. 2021. Т. 25. № 1. С. 140–145. DOI: 10.18698/2542–1468–2021–1–140–145.
3. Ле Мань Х. Сверточная нейронная сеть для решения задачи классификации // Труды МФТИ. 2016. Т. 8. № 3. С. 91–97. – URL: <https://cyberleninka.ru/article/n/svertochnaya-neyronnaya-set-dlya-resheniya-zadachi-klassifikatsii> (дата обращения: 23.05.2026).

4. Рысьмятова А. А. Использование сверточных нейронных сетей. М.: МГУ, 2016. 34 с.
5. Сикорский О. С. О влиянии цветового пространства изображения на обучение сверточной нейронной сети в задаче классификации изображений // Новые информационные технологии в автоматизированных системах. 2018. № 21. С. 340–343. – URL: <https://cyberleninka.ru/article/n/o-vliyanii-tsvetovogo-prostranstva-izobrazheniya-na-obuchenie-svyortochnoy-neyronnoy-seti-v-zadache-klassifikatsii-izobrazheniy> (дата обращения: 23.05.2026).
6. Смородинов А. Д. Исследование применимости сверточных нейронных сетей для задачи идентификации типа зависимости в наборах данных // Научно–исследовательский сетевой журнал «Инновационные системы и технологии». 2024. 2 апр.
7. Жданов А. Д., Жданов Д. Д., Хилик Е. Д. Автоматическое создание и разметка RGB–D изображений для обучения систем машинного зрения // Графикон–конференции по компьютерной графике и зрению. 2023. Т. 33. С. 25–32.
8. ГОСТ 30242–97. Дефекты соединений при сварке металлов плавлением. Классификация, обозначение и определения. – М.: ИПК Издательство стандартов, 1998. – 22 с.
9. Мазур И. И., Иванцов О. М. Безопасность трубопроводных систем. – М.: ИЦ Елима, 2004. – 1104 с.
10. Годовой отчет о деятельности Федеральной службы по экологическому, технологическому и атомному надзору (Ростехнадзор) за 2024 год. – М., 2025. – С. 168 (раздел «Объекты магистрального трубопроводного транспорта»).