

ДИАГНОСТИКА СВАРНЫХ СОЕДИНЕНИЙ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Тарасов Б.В.¹, Тимошкин В.В.², Борисова М.А.³

¹ НИ ТПУ, г. Томск (студент гр. 8E12 ОАР, ИШИТР), e-mail: bvt2@tpu.ru

² НИ ТПУ, г. Томск (доцент ОАР, ИШИТР), e-mail: timoshkinvv@tpu.ru

³ АО «СТНГ», г. Томск, e-mail: mari.borisova@stng.ru

Аннотация

В статье рассматривается использование сверточной нейронной сети YOLOv8m для выявления дефектов сварных соединений на основе радиографических изображений. Исследование включает анализ существующих методов неразрушающего контроля, выбор подходящей архитектуры сверточной нейронной сети, подготовку и разметку данных, а также обучение модели для детектирования и классификации дефектов сварных соединений.

Ключевые слова: сверточные нейронные сети, YOLOv8, сварные швы, радиографический контроль, неразрушающий контроль, дефекты сварки, компьютерное зрение.

Введение

Предприятия, связанные с производством и обучением сварщиков, сталкиваются с необходимостью эффективного контроля качества сварных соединений. Традиционные подходы требуют значительных временных и материальных затрат, особенно при анализе большого количества снимков в условиях интенсивного потока данных. Современные технологии и методы, используемые в радиографическом контроле, могут существенно повысить эффективность и снизить затраты. Одним из перспективных направлений является внедрение автоматизированных систем обработки изображений, основанных на алгоритмах машинного обучения и компьютерного зрения.

Разработка и применение нейросетевых технологий является важной задачей для таких предприятий, как АО «Стройтрансгаз», которые занимаются обучением и аттестацией сварщиков. В таких компаниях может накапливаться большой объем данных с изображениями сварных соединений, которые нужно оперативно обрабатывать. Применение нейронных сетей, при анализе рентгеновских снимков, позволит существенно ускорить обработку данных и повысить точность выявления дефектов. Такая система будет выполнять предварительную оценку качества сварных швов, давая возможность дефектоскопистам концентрироваться на наиболее сложных и неоднозначных случаях, повышая производительность труда и снижая нагрузку на специалистов.

Целью данной работы является разработка диагностической системы для выявления дефектов сварных швов с применением нейронных сетей. Данная система станет эффективным вспомогательным инструментом для дефектоскопистов.

Обзор решений

Современные исследования подтверждают эффективность применения искусственных нейронных сетей для детектирования и классификации дефектов сварных швов по радиографическим изображениям. В работе [1] показано, что использование искусственных нейронных сетей совместно с предварительной обработкой изображений обеспечивает высокую точность классификации различных дефектов, достигая 94,29 %, с отдельными дефектами до 100 %. Авторы исследования [2] предложили глубокую нейронную сеть (DNN), интегрирующую многоуровневые признаки, и добились средней точности классификации 91,36 %, значительно превышающей показатели традиционных подходов, таких как SVM и стандартные DNN.

В исследовании [3] был проведен сравнительный анализ искусственных нейронных сетей (ANN) и адаптивных нейро-нечётких систем (ANFIS), где ANFIS продемонстрировала преимущество, достигнув точности 82,6 % за счёт интеграции экспертных знаний. В статье [4] рассматривалась проблема несбалансированных данных при использовании глубоких сверточных нейронных сетей (DCNN). Авторы применили методы ресемплинга и получили среднюю точность 97,2 %, подчеркнув важность глубины сети и балансировки данных для повышения точности классификации.

В работе [5] использовалась модель на основе автоэнкодеров (SAE) и классификатора Softmax, которая показала максимальную точность классификации до 91,84%. Исследование [6] демонстрирует применение Mask R-CNN для задач сегментации, где модель эффективно выделяет объекты, что также подтверждает эффективность сверточных архитектур.

Наиболее перспективным подходом для задач детекции и классификации дефектов на радиографических снимках является архитектура YOLO, о чём свидетельствуют результаты исследования [7], где YOLOv8 продемонстрировала оптимальное сочетание высокой точности (94 %) и производительности по сравнению с другими моделями. Выбор архитектуры YOLO в настоящем исследовании обусловлен именно её способностью обеспечить быстрое и точное распознавание дефектов, что критически важно в условиях интенсивного анализа больших объёмов данных.

Таким образом, анализ литературы подтверждает обоснованность выбора архитектуры YOLO для решения задач диагностики сварных соединений, благодаря её высокой точности, скорости обработки и низким требованиям к вычислительным ресурсам.

Описание роботизированной системы цифровой радиографии «Транскан»

Исследование проводилось на базе роботизированной системы цифровой радиографии «Транскан», предназначенной для диагностики качества сварных соединений без нарушения целостности материала. Данная система формирует радиографическое изображение при помощи плоскостанельного детектора, который регистрирует рентгеновское излучение от источника ионизирующего излучения. Полученные данные передаются беспроводным способом на портативный компьютер оператора, оснащённый программным продуктом «Дисофт». На рис.1 представлена механическая компоновка устройств системы на трубе (рис. 1, а), а также схема передачи данных и взаимодействия элементов системы (рис. 1, б).




Рис. 1. Схема и принцип работы системы цифровой радиографии «Транскан»:

а – механическая компоновка устройств на трубе,

б – схема передачи данных и взаимодействия элементов системы

Подготовка и разметка данных

С АО «Стройтранснефтегаз» было получено 1455 файлов формата «DCM», для программы «Дисофт». В дальнейшем ко всем изображениям было применено минимальное

выравнивание, позволяющее сгладить фоновые неравномерности, а затем была использована оптимизация яркости по прямоугольной области. В результате было получено 3698 фотографий сварных швов, которые затем были размечены в соответствии ГОСТ 23055-78, и выделено 10 классов дефектов согласно ГОСТ 7512-82. После разметки всех изображений было установлено, что число фотографий без дефектов значительно превышает количество изображений с дефектами. Распределение изображений по наличию дефектов представлено на рис. 2, а. Анализ распределения классов дефектов, представленный на рис. 2, б показал, что на поры приходится 92,2% всех выявленных дефектов, что указывает на выраженный дисбаланс классов. В связи с этим для дальнейших исследований были отобраны только три класса с наибольшим числом образцов.




Рис. 2. Круговые диаграммы распределения фотографий:
а – распределение по наличию дефектов; б – распределение по классам дефектов

Обучение модели

На следующем этапе была выполнена процедура обучения нейронной сети YOLOv8m. Для формирования выборок были использованы данные трёх наиболее представленных классов: 70 % снимков отнесли к обучающему набору, 20 % – к валидационному и 10 % – к тестовому. На первом шаге обучения сеть тренировали в течение 100 эпох при размере входного изображения 1024 пикселя.

Матрица ошибок (рис. 3, а) показывает, что модель YOLOv8 демонстрирует удовлетворительные результаты в распознавании класса Aa, однако фон часто ошибочно распознаётся как дефект данного класса. В то же время точность распознавания классов Ab и Ac значительно ниже. Основной причиной этого является выраженный дисбаланс обучающей выборки (рис. 3, б), в которой класс Aa существенно преобладает по числу примеров. Подобный дисбаланс приводит к смещению предсказаний модели в сторону доминирующего класса и, как следствие, к снижению качества распознавания менее представленных классов. Метрики, полученные на тестовой выборке представлены в таблице 1.

Таблица 1. Метрики точности по классам на тестовой выборке

Класс	Количество фотографий	Количество объектов	Precision	Recall	mAP50	mAP50-95
Aa	49	133	0,457	0,575	0,498	0,178
Ac	5	5	0,334	0,4	0,3	0,103
Ab	11	11	0,145	0,455	0,301	0,176
Среднее значение			0,366	0,476	0,366	0,152




Рис. 3. Результаты валидации модели:
а – матрица ошибок; б – распределение объектов по классам

Затем были проведены эксперименты по исследованию влияния различных гиперпараметров модели на точность детекции дефектов. Однако полученные изменения не дали существенного прироста качества модели. В связи с этим было решено сформировать новый набор данных из 100 изображений, содержащих преимущественно один доминирующий класс дефектов. Дополнительно применялся фильтр с максимальным выравниванием изображений, позволивший улучшить визуальную различимость дефектов и повысить точность ручной разметки данных. На основе данного набора изображений были проведены исследования влияния различных гиперпараметров, результаты которых представлены в таблице 2.


Таблица 2. Влияние гиперпараметров на точность модели

Количество эпох	100	200	100	100	100	100	100	100	100
Разрешение изображения	1024	1024	1152	1280	1408	1024	1024	1280	640
Аугментация	-	+	+	+	+	+	+	+	+
Выбор модели	m	m	m	m	m	l	x	m	m
Batch size	4	4	4	4	4	4	4	8	16
Использовано памяти GPU	4,5 G	4,5 G	5,4 G	6,5 G	7,8 G	6,7 G	8,5 G	10,6 G	6,9 G
Время обучения, мин	14	26	17	17	20	18	31	15	7
Среднее арифметическое метрик	0,749	0,717	0,689	0,752	0,723	0,713	0,701	0,741	0,732

Результаты

В результате проведённых экспериментов наилучшие показатели были получены при использовании модели YOLOv8m, обученной на протяжении 100 эпох, с разрешением входных изображений 1280 пикселей, применением методов аугментации и batch size, равным 4. При пороге уверенности 0,25 итоговые значения метрик составили: Precision = 1,0, Recall = 0,7076, mAP50 = 0,8072, mAP50-95 = 0,4956. Высокое значение Precision говорит об отсутствии ложных срабатываний, то есть все обнаруженные дефекты идентифицированы моделью корректно. Однако относительно низкое значение Recall свидетельствует о том, что примерно 30 % дефектов были пропущены моделью. Средняя точность при пороге IoU $\geq 0,5$ демонстрирует удовлетворительную локализацию объектов, но существенное снижение точности при увеличении диапазона IoU (от 0,5 до 0,95) указывает на необходимость дальнейшего совершенствования модели для повышения полноты обнаружения дефектов. Ниже приведено сравнение результатов работы модели и исходной ручной разметки дефектов на одном и том же изображении. На изображении рис. 4а представлены дефекты,

обнаруженные нейронной сетью, с соответствующими значениями уверенности модели; на изображении рис. 4, б отображена исходная разметка, выполненная вручную.



*Рис. 4. Сравнение предсказаний модели и исходной разметки
а – предсказанная разметка модели, б – ручная разметка изображений*

Заключение

В результате проведённого исследования была разработана модель на основе сверточной нейронной сети YOLOv8m, предназначенная для распознавания дефектов сварных соединений по цифровым радиографическим изображениям. Полученные результаты подтвердили эффективность предложенного подхода и позволили определить оптимальные параметры модели. Вместе с тем, выявленное ограничение, связанное с недостаточной полнотой ($Recall = 0,7076$), указывает на необходимость увеличения набора изображений различных дефектов. Это даст возможность улучшить работу нейронной сети, повысив её способность к детекции и классификации более широкого спектра дефектов.

При сопоставлении разработанной модели с аналогичными исследованиями [1–5] следует отметить, что достигнутые показатели точности (Precision, Recall, mAP50 и mAP50–95) в настоящее время уступают известным результатам. В опубликованных работах сообщается о точности распознавания дефектов на уровне от 82 % до 94 %, а при использовании специализированных глубоких сетей с балансировкой классов достигаются значения до 97,2 %. Основными причинами более низкой результативности в рамках данной работы являются ограниченный объём и выраженная несбалансированность набора данных.

Однако разработанная модель обладает важным преимуществом по скорости обработки данных. Среднее время анализа одного радиографического изображения составляет около 88,7 мс на GPU RTX 3060, что эквивалентно примерно 11 кадрам в секунду (FPS). В аналогичных исследованиях параметры быстродействия зачастую не приводятся явно. Таким образом, предложенная модель демонстрирует превосходство по скорости обработки по сравнению с большинством известных решений. Это преимущество особенно ценно для мобильных радиографических комплексов, таких как система «Транскан», которая комплектуется с высокопроизводительными ноутбуками, обеспечивая оперативное выявление дефектов непосредственно в полевых условиях.

Таким образом, применение разработанной нейросетевой модели позволяет расширить арсенал технологий в области неразрушающего контроля сварных соединений и в перспективе повысить общую эффективность процесса выявления дефектов. Для дальнейшего развития системы необходимо сконцентрироваться на расширении обучающего набора данных и проведении дополнительных исследований, направленных на повышение точности и полноты распознавания дефектов.

Список использованных источников

1. Al-Ghamdi S.A., Emam A.S., Abouelatta O.B. Automatic classification of welding defects using neural network and image processing techniques // Albaha University Journal of Basic and Applied Sciences. – 2017. – Vol. 1, Issue 1. – P. 17–25.
2. Yang L., Jiang H. Weld defect classification in radiographic images using unified deep neural network with multi-level features // Journal of Intelligent Manufacturing. – 2020.
3. Zapata J., Vilar R., Ruiz R. Performance evaluation of an automatic inspection system of weld defects in radiographic images based on neuro-classifiers // Expert Systems with Applications. – 2011. – Vol. 38, Issue 7. – P. 8812–8824.
4. Hou W., Wei Y., Jin Y., Zhu C. Deep features based on a DCNN model for classifying imbalanced weld flaw types // Measurement. – 2019. – Vol. 131. – P. 482–489.
5. Hou W., Wei Y., Guo J., Jin Y., Zhu C. Automatic detection of welding defects using deep neural network // Journal of Physics: Conference Series. – 2017. – Vol. 933. – Article ID 012006.
6. 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.
7. ГОСТ 7512–82. Контроль неразрушающий. Соединения сварные. Радиографический метод. – Москва: Изд-во стандартов, 1982. – 39 с.
8. ГОСТ 23055–78. Контроль неразрушающий. Дефекты сварных соединений при радиографическом контроле. Классификация и обозначения. – Москва: Изд-во стандартов, 1978. – 8 с.