

УДК 004.89:621.791:620.179.152.1
DOI



CC BY 4.0

ПРИМЕНЕНИЕ МОДИФИЦИРОВАННОЙ АРХИТЕКТУРЫ YOLO ДЛЯ ЗАДАЧ РАДИАЦИОННОГО НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ СВАРНЫХ СОЕДИНЕНИЙ

Корчагин В. Д. ORCID ID 0009-0003-1773-0085,
Сударев А. В. ORCID ID 0009-0003-5960-954X,
Кувшинников В. С. ORCID ID 0000-0002-2565-2510,
Ковшов Е. Е. ORCID ID 0000-0003-4758-1730

*Акционерное общество «Научно-исследовательский и конструкторский институт
монтажной технологии – Атомстрой», Москва, Российская Федерация,
e-mail: valerak249@gmail.com*

Представлена адаптивная модификация архитектуры однопроходного детектора YOLOv8, разработанная специально для задач автоматической детекции дефектов на рентгенограммах сварных соединений. Исследование выявило критическую проблему существующих решений – потерю точности до 12–18 % при изменении условий контроля (толщина материала, угол просвечивания, тип источника), что обусловлено использованием разнородных датасетов (наборов данных) и статических архитектур без учета доменных смещений. Предложенная архитектура «DICONDE-YOLO» включает четыре ключевых нововведения: замену блока SPPF на ASPP для многоканального извлечения признаков, интеграцию модуля эффективного канального внимания ECA для динамического перераспределения каналов, замену блоков C2F на комбинацию глубинных сверток и max-pooling для адаптивного рецептивного поля, а также токенизацию DICOM-метаданных с мультимодальным слиянием. Формирование валидированного датасета из 130 тыс. синтезированных изображений позволило преодолеть проблему разнородности разметки открытых наборов данных. Экспериментальные результаты на GPU RTX 3080 показали существенное повышение метрик: mAP@0.5 с 0,67 до 0,94, precision – до 0,85, recall – до 0,84 при сокращении времени вывода с 20,18 до 18,73 мс. Результаты подтверждают эффективность механизма динамической маршрутизации признаков для компенсации доменных смещений без этапа переобучения. Внедрение предлагаемой архитектуры в производственные линии неразрушающего контроля способно снизить нагрузку на специалистов по дефектоскопии и уменьшить долю пропускаемых дефектов при серийном производстве сварных конструкций, что особенно актуально в условиях дефицита квалифицированных кадров и ужесточения требований к качеству продукции.

Ключевые слова: неразрушающий контроль, YOLO, модификация нейронной сети, детекция дефектов, сварные соединения, компьютерное зрение, метаданные, DICONDE

APPLICATION OF A MODIFIED YOLO ARCHITECTURE FOR RADIATION NON-DESTRUCTIVE TESTING OF WELDED JOINTS

Korchagin V. D. ORCID ID 0009-0003-1773-0085,
Sudarev A. V. ORCID ID 0009-0003-5960-954X,
Kuvshinnikov V. S. ORCID ID 0000-0002-2565-2510,
Kovshov E. E. ORCID ID 0000-0003-4758-1730

*Joint Stock Company Research and Design Institute of Installation Technology – Atomstroy,
Moscow, Russian Federation, e-mail: valerak249@gmail.com*

An adaptive modification of the architecture of the YOLOv8 single-pass detector is presented, specially developed for tasks of automatic detection of defects on X-rays of welded joints. The study revealed a critical problem in existing solutions – loss of accuracy up to 12–18 % when changing control conditions (material thickness, irradiation angle, source type) due to the use of heterogeneous datasets and static architectures without consideration of domain shifts. The proposed architecture «DICONDE-YOLO» includes four key innovations: replacement of the SPPF block with ASPP for multi-channel feature extraction, integration of an efficient ECA channel focus module for dynamic channel reallocation, Replacing C2F blocks with a combination of deep bundles and max-pooling for the adaptive receptive field, and tokenization of DICOM metadata with multimodal fusion. The formation of a validated dataset from 130,000 synthesized images has overcome the problem of heterogeneous markup of open data sets. Experimental results on the RTX 3080 GPU showed a significant increase in metrics: mAP@0.5 from 0.67 to 0.94, precision – to 0.85, recall – to 0.84 with a reduction in output time from 20.18 to 18.73 ms. The results confirm the effectiveness of dynamic feature routing to compensate for domain shifts without a retraining step. The implementation of the proposed architecture in production lines of non-destructive inspection can reduce the burden on specialists in defect detection and reduce the ratio of defects that are missed during serial production of welded structures. This is particularly relevant in the context of a shortage of qualified personnel and stricter product quality requirements.

Keywords: non-destructive testing, YOLO, neural network modification, defect detection, welded joints, computer vision, metadata, DICONDE

Введение

Радиационный неразрушающий контроль (РНК) сварных соединений остается одним из основных методов обеспечения качества продукции в нефтегазовой, атомной и авиакосмической отраслях. Традиционно анализ рентгенографических изображений выполняется специалистами-дефектоскопистами. Монотонный труд требует длительной концентрации и неизбежно приводит к ошибкам, вызванным человеческим фактором.

В последние годы активно исследуются возможности применения сверточных нейронных сетей для автоматической детекции дефектов на рентгенограммах. Анализ публикаций [1–3] показал, что подавляющее большинство существующих решений использует однопроходные детекторы семейства YOLO (v5–v8). Особенности применения архитектур данного семейства рассмотрены в работах [4–6]. Модели демонстрируют баланс между точностью и скоростью вывода, что является критически важным свойством для интеграции в производственные линии. Вместе с тем стандартные версии YOLO не учитывают существенную изменчивость условий радиационного контроля: различия в геометрии шва, плотности материала, уровне шума, угле просвечивания. Анализ известных публикаций [7–9] показал, что для обучения использовались разнородные датасеты из открытых источников. Ранее проведенные исследования [10, 11] на базе аналогичного датасета показали, что подобные данные сопровождаются разметкой неудовлетворительного качества, что усугубляет проблему. Если модель обучается на разнородной выборке без учета доменных смещений, это приводит к снижению точности в применении к результатам контроля других типов конструкций в иных условиях экспонирования.

Цель исследования – разработка адаптивной модификации на базе YOLOv8 для детекции дефектов сварных соединений в условиях меняющейся входной информации и формирование валидированного датасета рентгенографических снимков сварных швов различных типов.

Материалы и методы исследования

Задача детекции дефектов на рентгенограммах РНК формализуется в виде многоклассовой детекции объектов в условиях изменяющихся входных данных.

Пусть $I = \{i_1, i_2, \dots, i_N\}$ – множество рентгенографических снимков сварных швов различных типов. Каждый снимок (рентгенограмма) сопровождается

DICOM-метаданными (DICOM – Digital Imaging and Communications in Medicine) $M_i = \langle S, A, D, T \rangle$, где S – источник излучения (рентгеновский/изотопный); A – угол просвечивания; D – толщина металла; T – тип сварного соединения.

Необходимо построить детектор $f: I \times M \rightarrow Y$, где $Y = \{y_1, y_2, \dots, y_k\}$ – множество обнаруженных дефектов с классами $\{pore, inclusion, crack, undercut, porosity\}$ и ограничивающими рамками

$$\langle x_{min}, x_{max}, y_{min}, y_{max} \rangle,$$

удовлетворяющий условию

$$mAP@0.5(I) \geq 0.9$$

при $t_{inference}(i) < T_{threshold}$ (1)

при выполнении условия устойчивости к доменным сдвигам:

$$\frac{mAP(I_{source}) - mAP(I_{target})}{mAP(I_{source})} \leq 0.15. \quad (2)$$

Применение многих стандартных аугментаций к рассматриваемой задаче ограничено, что является ее значимой отличительной особенностью. Геометрические аугментации и аугментации цветового пространства, подходящие для фотоматериалов, некорректно изменяют изображение швов и дефектов сварных соединений на рентгенограммах. Адаптация нейросетевой архитектуры способна в ряде случаев снизить необходимость в аугментации данных.

Автоматическая детекция дефектов сварных соединений по результатам РНК активно исследуется в рамках концепции Индустрии 4.0 [12] и NDE 4.0 [13]. В работах [1–3] демонстрируется применение YOLOv7 и YOLOv8 для обнаружения пор, непроваров и трещин на рентгенограммах. Отмечается высокая чувствительность модели к качеству входных снимков: при изменении условий экспонирования (угол просвечивания, тип источника проникающего излучения) точность снижается на 12–18 %. Для повышения устойчивости к условиям экспонирования в литературе предлагается ряд архитектурных модификаций. Наибольшую популярность получили модули внимания: CBAM [14] и SE-блоки [15]. Их интеграция в блок C2F рассмотрена в работе [16]. Дополнительно применяются адаптивные ядра свертки [17], позволяющие изменять рецептивное поле в зависимости от локального контраста шва.

Вышесказанное позволяет сделать вывод, что, несмотря на широкое применение различных моделей семейства YOLO для детекции дефектов сварных соединений, существующие работы не уделяют достаточного внимания адаптации модели к изменяющимся условиям контроля. Использование разнородных датасетов и статических архитектур ограничивает обобщающую способность систем. Разработанный модуль динамической маршрутизации признаков, представленный в настоящей работе, позволяет частично решить эту проблему, что подтверждается экспериментальными результатами. Под динамической маршрутизацией признаков понимается механизм адаптивного перераспределения информативных сигналов в нейросетевой архитектуре, при котором весовые коэффициенты каналов и слоев формируются на основе входного набора данных – в частности, токенизированных DICOM-метаданных об условиях экспонирования – без применения дополнительных этапов переобучения.

Базовая архитектура детектора YOLOv8 состоит из трех основных компонентов: основная часть (backbone) на базе блоков C2F, шейная часть (neck) типа PANet [18] с многоуровневой агрегацией признаков и свободными якорями (anchor-free) для детектирующей головы, обучающейся через комбинацию функций потерь CIoU (Complete Intersection over Union). Для обеспечения адаптивности модели к изменяющимся условиям радиационного контроля предложена модификация архитектуры «DICONDE-YOLO», включающая четыре ключевых изменения: замену SPPF (Spatial Pyramid Pooling Fast) на ASPP-блок (Atrous Spatial Pyramid Pooling) [19], интеграцию модуля ECA (Efficient Channel Attention), замену C2F-блоков на комбинацию DC (Depthwise Convolution) [20] и MDC (Max Pooling + Depthwise Convolution) [21] блоков, токенизацию DICOM-метаданных и мультимодальное слияние. Схемы оригинальной и модифицированной архитектур представлены на рис. 1 и 2.

В оригинальном YOLOv8 блок пространственного пулинга SPPF отвечает за агрегацию контекстной информации с разными масштабами рецептивного поля. Для повышения чувствительности к дефектам различной геометрии при неизменной частоте дискретизации признаков предложен модуль ASPP, который заменяет SPPF в конце основной части архитектуры.

Модуль ASPP использует параллельные свертки с разными коэффициентами дилатации $\alpha \in \{1, 2, 4, 8\}$ для извлечения признаков на множестве масштабов без потери

пространственного разрешения. Формирование итогового вектора осуществляется через конкатенацию по каналу и последующую 1×1 свертку:

$$y = \text{Conv}_{1 \times 1} \left(\bigoplus_{k=1}^4 \text{Conv}^{\alpha_k}(x) \right) + x. \quad (3)$$

Для задачи РНК это означает возможность обнаружения как локальных дефектов (поры, включения), так и протяженных (непровар, трещины) с сохранением пространственной детализации.

На выходе каждого слоя основной части архитектуры внедрен модуль эффективного канального внимания ECA, который динамически взвешивает каналы признаков на основе локальных взаимодействий без полносвязных слоев. Для канала вычисляется:

$$\omega_c = \sigma(\text{GAP}(x)), \quad \omega = 1 + \gamma^* \sum_{j=1}^k \theta_j x_j, \quad (4)$$

где γ – обучаемый параметр, k определяет как функция от размера канала.

ECA позволяет модели перераспределить признаки по каналам в зависимости от локального контраста снимка, что критично при изменении плотности материала и уровня шума. В середине основной части архитектуры заменены три последовательных блока C2F на чередование DC и MDC блоков:

DC (Depthwise Convolution) – модуль с групповой сверткой, выполняющей независимую фильтрацию каждого канала. Это снижает вычислительную нагрузку и позволяет эффективно извлекать локальные текстурные признаки дефектов при сохранении канальных особенностей;

MDC (Max Pooling + Depthwise Convolution) – расширенный блок, включающий последовательность

$$\text{Conv}_{dw} \rightarrow \text{ReLU} \rightarrow \text{MaxPool}(k=2).$$

Добавление операции max-pooling позволяет модели извлекать наиболее выраженные паттерны с высокой амплитудой (контрастные дефекты), что особенно эффективно при детекции протяженных областей непроваров и трещин.

Формирование результата:

$$y = \text{DC}(x) + \text{MDC}(x),$$

$$y \leftarrow \text{Norm}(\text{ReLU}(y)). \quad (5)$$

Такая комбинация обеспечивает адаптивность рецептивного поля и динамический отбор приоритетных каналов, что особенно эффективно при детекции дефектов с низкой локальной контрастностью (например, непровары корня сварного шва).





Рис. 1. Оригинальная архитектура YOLOv8
Примечание: составлен авторами на основе источника [10]



Добавление токенизации DICOM-метаданных позволяет интегрировать специфичный для задач РНК набор информации: данные об источнике излучения, угол просвечивания, фокусное расстояние, толщина металла, тип сварного соединения.

Рассмотрим изображение i с набором атрибутов $M_i = \{m_{i1}, m_{i2}, m_{i3}\}$, где m_{i1} = «slag» – категориальный атрибут, m_{i2} = 12,5 – числовой атрибут температуры поверхности m_{i3} = «СТ» – текстовый атрибут, отвечающий за тип контроля.

Фиксируются параметры стандартизации обучающей выборки на значениях:

$m_{i2} = 15, \sigma_2 = 4,2$. Для категориального атрибута задается словарь

$$E_{defect} = \{\text{inclusion, slag, crease, oil_spot}\}$$

с однопроходным кодированием размерности $d=4$. Тогда токенизация отдельных атрибутов рассчитывается следующим образом:

$$\psi_1(\text{«slag»}) = [0, 1, 0, 0] \in \mathbb{R}^4, \quad (6)$$

$$\psi_2(12.5) = \frac{12.5 - 15}{4.2} = -0.595 \in \mathbb{R}^1, \quad (7)$$

$$\psi_3(\text{«СТ»}) = [0, 0, 1] \in \mathbb{R}^3. \quad (8)$$

Итоговый вектор метаданных до нормализации:

$$z'_i = \text{Concat}([0, 1, 0, 0], [-0.595], [0, 0, 1]) = [0, 1, 0, 0, -0.595, 0, 0, 1] \in \mathbb{R}^8. \quad (9)$$

После применения L2-нормализации $\omega(\cdot)$:

$$z_i = \frac{z'_i}{\|z'_i\|_2} = [0.354, 0.354, 0, 0, -0.211, 0, 0, 0.354]. \quad (10)$$

Механизм токенизации и стандартизации позволяет модели компенсировать доменные смещения за счет явного учета условий съемки и геометрии сварного соединения, что особенно критично при необходимости анализа результатов контроля новых типов конструкций или полученных на новом оборудовании РНК.

Формирование достоверного датасета рентгенограмм сварных соединений стало одной из ключевых задач исследования. Изначально использовались открытые наборы данных (NDT datasets, Kaggle-коллекции, архивы лабораторий РНК), однако их объединение в единую выборку выявило критические проблемы: разный формат снимков (DICOM против PNG/JPG), неоднородную плотность изображения, отсутствие стандартизированного глоссария дефектов и субъективность экспертной разметки. Перечень имеющихся классов дефектов и их описаний, а также пример экземпляра, полученного на основе вычислительного эксперимента, представлены в табл. 1 и на рис. 3 соответственно.

Для решения этих проблем при помощи симулятора промышленной радиографии [22–24] был сформирован валидированный датасет из 300 000 искусственных изображений, максимально приближенных к реальным примерам объектов контроля и имеющихся дефектов. Достоверность разметки обеспечивается посредством программной генерации точных координат положения дефектов и их типа.

Таблица 1

Классы дефектов и их описание из первичного эксперимента

Класс	Описание
crease	складка
crescent_gap	серповидный зазор
inclusion	включение
oil_spot	масляное пятно
punching_hole	дефект штамповки
rolled_pit	прокатная выемка
silk_spot	волосовина
waist_folding	клиновидный дефект
water_spot	водяное пятно
welding_line	линия сварного шва

Примечание: составлена авторами на основе источника [10].

Предобработка включала: конвертацию в 16-битный формат градации серого (16-bit grayscale), гамма-коррекцию ($\gamma = 0,8$), CLAHE (Contrast Limited Adaptive Histogram Equalization) с ограничением контраста 2,5 и адаптивное шумоподавление (NL-means). Аугментация выполнялась на уровне батча во время обучения с вероятностью 0.7: повороты $\pm 15^\circ$, гамма-сдвиг $[-0,3, +0,3]$, аддитивный белый шум ($\sigma = 0,02$), локальная контрастная нормализация. Геометрические трансформации ограничены из-за специфики РНК: поворо-

ты $> \pm 15^\circ$ могут искажать ориентацию шва относительно источника. Разбиение выборки проводилось в следующем соотношении: обучающая train – 70 %, проверочная val – 15 %, тестовая test – 15 %.




Рис. 3. Выявленные дефекты с низкой визуальной контрастностью и высокой внутриклассовой вариативностью
Примечание: составлен авторами по результатам данного исследования

В отличие от работы [10], где использовалась комбинированная выборка из открытых источников, включающая дефекты визуального контроля, в настоящем исследовании датасет сформирован исключительно из дефектов сварных соединений, регламентированных нормативной документацией по радиационному контролю. Для достоверности в ходе обучения также использовались данные, взятые из работы [10]. Перечень дополнительных классов дефектов, их описание и количественное распределение в синтезированном датасете представлены в табл. 2.

Обучение проводилось на GPU NVIDIA RTX 3080 с использованием библиотеки Ultralytics. Параметры обучения: optimizer – AdamW (weight decay = 0,0005), batch = 16, epochs = 150. Оценка проводилась по метрикам: mAP@0.5 (точность детекции с порогом $\text{IoU} \geq 0,5$), mAP@0.5–0.95, precision, recall, а также среднее время инференса (Inference time) на одной рентгенограмме. Для оценки адаптивности использовался метод кросс-валидации, при котором модель обучалась на подмножестве типов сварных швов и проверялась на других типах, а также производилась симуляция изменений условий съемки. Пример сравнительного результата детекции дефектов на основе экспериментального применения YOLOv8 и «DICONDE-YOLO», а также таблица основных метрик представлены на рис. 4 и в табл. 2 соответственно.

Таблица 2

Классы дефектов и их описание из итогового вычислительного эксперимента

Класс (русский / английский)	Описание дефекта	Кол-во экземпляров	Доля, %
Пора / pore	Одиночная замкнутая полость округлой или овальной формы	70 000	23,3
Скопление пор / clustered_pores	Группа из трех и более газовых пор, расположенных на расстоянии менее трех диаметров друг от друга. Рассматривается как единый дефект, подлежащий оценке по протяженности согласно ГОСТ 23055-78	40 000	13,3
Неметаллическое включение / inclusion	Частица неметаллического происхождения (оксид, флюс, вольфрам), оставшаяся в металле шва. На рентгенограмме имеет неправильную форму с нечеткими границами и переменной оптической плотностью	50 000	16,7
Шлаковое включение (единичное) / slag	Единичное включение сварочного шлака вытянутой или угловатой формы. На рентгенограмме обычно светлее пор, имеет неровные очертания	45 000	15,0
Скопление шлаковых включений / slag_cluster	Группа шлаковых включений, сосредоточенных на ограниченном участке шва. Протяженность скопления не должна превышать 1,5 длины допустимого единичного включения по нормативным требованиям	30 000	10,0
Непровар / faulty_fusion	Отсутствие сплавления между основным и наплавленным металлом либо между отдельными валиками. На рентгенограмме проявляется в виде прямолинейной или слабоизогнутой темной полосы с четкими границами	35 000	11,7
Трещина / crack	Несплошность, вызванная местным разрывом металла шва или зоны термического влияния. Трещины любого вида не допускаются согласно ГОСТ 23055-78	30 000	10,0
Итого		300 000	100

Примечание: составлена автором на основе источников [25–27].




Рис. 4. Экспериментальное применение YOLOv8 и DICONDE-YOLO для задач детекции дефектов
Примечание: составлен авторами по результатам данного исследования

Таблица 2

Основные метрики

Модель	mAP@0.5	mAP@0.5-0.95	Precision	Recall	Inference time
YOLOv8	0,67	0,34	0,63	0,65	20,18 мс
DICONDE-YOLO	0,94	0,56	0,85	0,84	18,73 мс

Примечание: составлена авторами на основе полученных данных в ходе исследования.

На основе проведенных вычислительных экспериментов установлено, что предложенная модификация архитектуры YOLOv8 (архитектура DICONDE-YOLO) обеспечивает сохранение показателей детекции дефектов сварных соединений на более высоком уровне при изменении условий радиационного контроля. Ключевой вклад исследования заключается в разработке механизма динамической маршрутизации признаков, позволяющего модели компенсировать доменные сдвиги без дополнительных этапов переобучения.

Сравнительный анализ показывает, что использование базовой архитектуры YOLOv8 без адаптации к условиям РНК приводит к падению mAP@0.5 67 % против 94 % при переходе между типами сварных соединений – в первую очередь из-за игнорирования доменной информации о геометрии шва и параметрах экспонирования. Данное наблюдение подтверждает выводы, сделанные в предшествующих авторских работах [28–30], где было показано, что базовые архитектуры семейства YOLO не способны удовлетворительно обрабатывать разнородные рентгенограммы без учета явно приведенных условий съемки и параметров контроля.

Особый интерес представляет результат по метрике precision (0,63 → 0,85) – рост на 22 п. п. свидетельствует о существенном снижении доли ложноположительных срабатываний, что критично для производственной эксплуатации: каждый ложный сигнал вызывает перепроверку снимка инспектором и снижает продуктивность кон-

троля. С практической точки зрения внедрение адаптивной детекции способствует снижению нагрузки на инспекторов, сокращает время контроля и уменьшает долю пропускаемых дефектов при серийном производстве сварных конструкций. Снижение времени инференса с 20,18 до 18,73 при одновременном росте показателя точности подтверждает корректность выбора замены блока C2F на комбинацию DC+MDC: уменьшение количества параметров в канальном пути компенсирует накладные расходы от модуля ECA и ASPP.

Специфика формирования валидированного датасета из 130 000 синтезированных размеченных изображений решила проблему, выявленную в работе [29]. Использование синтезированных данных с детерминированной разметкой позволило отделить влияние качества модели от влияния качества обучающей выборки и явно продемонстрировать проблему и эффект от внесенных в базовую архитектуру изменений.

Ограничения исследования связаны с конечной репрезентативностью данных в наборе, включая типы соединений: изменение материала или типа сварного соединения может потребовать переобучение.

Перспективы дальнейшей работы включают:

- расширение датасета за счет активных методов разметки и кросс-промышленного обмена данными;

- интеграцию комбинации методов контроля (радиографический + ультразвуковой/визуальный);

– проведение квантования модели до уровня INT8 с целью внедрения в портативные устройства для РНК контроля.

Заключение

В ходе исследования разработана адаптивная модификация архитектуры однопроходного детектора DICONDE-YOLO, предназначенная для поддержки принятия решений в задачах РНК сварных соединений. Модификация заключается в четырех ключевых изменениях:

- замене блока SPPF на ASPP-блок с коэффициентами дилатации {1, 6, 12, 18} для многоканального извлечения признаков;
- внедрении модуля эффективного канального внимания ECA в ключевые слои центральной части архитектуры;
- замене блоков C2F на комбинацию DC и MDC-блоков для создания адаптивного рецептивного поля;
- токенизации DICOM-метаданных с мультимодальным слиянием.

Экспериментальные результаты показали, что разработанный валидированный датасет из 130 000 синтезированных изображений позволил преодолеть проблему неоднородной разметки открытых наборов данных и обеспечить достоверную оценку обобщающей способности модели. Результаты подтверждают гипотезу, что динамическая маршрутизация признаков за счет токенизации DICOM-метаданных позволяет компенсировать доменные сдвиги без дополнительных этапов обучения.

Практическая значимость исследования заключается в том, что полученные результаты указывают на потенциальную применимость разработанной архитектуры DICONDE-YOLO в качестве инструмента поддержки принятия решений для дефектоскописта при радиационном контроле сварных соединений. Предложенный подход демонстрирует устойчивость к изменению условий экспонирования и позволяет повысить точность автоматической детекции дефектов на синтезированных рентгенограммах. Однако промышленная эффективность системы требует дополнительной валидации на реальных производственных данных, включая снимки с различных типов оборудования, при варьировании технологических параметров сварки и в условиях серийного контроля. Пилотные испытания с участием квалифицированных инспекторов необходимы для подтверждения снижения нагрузки на персонал и уменьшения доли пропускаемых дефектов в реальном производственном цикле, особенно в атомной и нефтегазовой отраслях, где требования к качеству сварных конструкций регла-

ментируются действующими нормативными документами.

Список литературы

1. Сотников А. Л., Ковальчик Р. В., Орлов А. А. Разработка архитектуры веб-приложения для детекции объектов на рентгеновских снимках сварных соединений // Научные технологии и оборудование в промышленности и строительстве. 2025. № 8 (82). С. 53–61. URL: <https://www.elibrary.ru/item.asp?id=82678004> (дата обращения: 05.06.2026).
2. Du F. J., Jiao S. J. Improvement of Lightweight Convolutional Neural Network Model Based on YOLO Algorithm and Its Research in Pavement Defect Detection // Sensors. 2022. Vol. 22. № 9. DOI: 10.3390/s22093537.
3. Васильев М. Е., Коськин А. В., Шалимов А. С. Автоматизация обнаружения дефектов поверхностей изделий на основе сверточных нейронных сетей // Вестник компьютерных и информационных технологий. 2024. Т. 21. № 3 (237). С. 30–36. URL: <https://elibrary.ru/item.asp?id=65663298> (дата обращения: 05.06.2026). DOI: 10.14489/vkit.2024.03.pp.030-036.
4. Yasmine G., Maha G., Hicham M. Overview of single-stage object detection models: from Yolov1 to Yolov7 // 2023 International Wireless Communications and Mobile Computing (IWCMC). IEEE, 2023. P. 1579–1584. DOI: 10.1109/IWCMC58020.2023.10182423.
5. Сотников А. Л., Ковальчик Р. В., Орлов А. А. Разработка интеллектуальной системы распознавания объектов на рентгеновских снимках сварных соединений // Вестник Череповецкого государственного университета. 2026. № 1. С. 47–65. DOI: 10.23859/1994-0637-2026-1-130-4.
6. Wang X., Zscherpel U., Tripicchio P., D'Avella S., Zhang B., Wu J., Liang Z., Zhou S., Yu X. A comprehensive review of welding defect recognition from X-ray images // Journal of Manufacturing Processes. 2025. Vol. 140. P. 161–180. URL: <https://www.sciencedirect.com/journal/journal-of-manufacturing-processes> (дата обращения: 06.06.2026). DOI: 10.1016/j.jmapro.2025.02.039.
7. García-Pérez A., Gómez-Silva M. J., De La Escalera-Hueso A. Improving automatic defect recognition on GDXRay castings dataset by introducing GenAI synthetic training data // NDT & E International. 2025. Vol. 151. P. 103303. DOI: 10.1016/j.ndteint.2024.103303.
8. Usamentiaga R., Venegas P. Infrared imaging and NDT // Applied Sciences (Switzerland). 2021. Vol. 11. Is. 7. DOI: 10.3390/app11073024.
9. Topp M., Els C., Nestler D. Artificial Intelligence in NDT and NDE: Overview and Current Status // Handbook of Nondestructive Evaluation 4.0. 2025. P. 1–30. URL: <https://link.springer.com/referencework/10.1007/978-3-030-48200-4> (дата обращения: 05.06.2026).
10. Корчагин В. Д., Кувшинников В. С., Ковшов Е. Е. Критериальный анализ моделей обработки данных радиационного неразрушающего контроля // International Journal of Open Information Technologies. 2024. Т. 12. № 4. С. 23–31. URL: <https://elibrary.ru/item.asp?id=65612526> (дата обращения: 05.06.2026).
11. Корчагин В. Д. Анализ современных SOTA-архитектур искусственных нейронных сетей для решения задач классификации изображений и детекции объектов // Программные системы и вычислительные методы. 2023. № 4. С. 73–87. URL: https://nbpublish.com/library_read_article.php?id=69306 (дата обращения: 05.06.2026). DOI: 10.7256/2454-0714.2023.4.69306.
12. Гинзбург А. В., Адамцевич Л. А., Адамцевич А. О. Строительная отрасль и концепция «Индустрия 4.0»: обзор // Вестник МГСУ. 2021. Т. 16. № 7. С. 885–911. URL: <https://cyberleninka.ru/article/n/stroitel'naya-otrasl-i-kontseptsiya-industriya-4-0-obzor> (дата обращения: 05.06.2026).
13. Maev R. G. Introduction to nde nde 4.0 // Research in Nondestructive Evaluation. 2020. Т. 31. № 5–6. С. 271–274. DOI: 10.1080/09349847.2020.1817641.

14. Song Z., Yao H., Tian D., Zhan G., Gu Y. Segmentation method of U-net sheet metal engineering drawing based on CBAM attention mechanism // *AI EDAM*. 2025. Vol. 39. P. e14. DOI: 10.1017/S0890060424000301.
15. Popuri J. R., Ackshay N. R., Nitish N. H., Kumar D. D., Varun P. G. Automated weld defect detection using gated attention and squeeze and excitation fusion U-Net // *Scientific Reports*. 2025. Vol. 15. Is. 1. P. 40623. DOI: 10.1038/s41598-025-24406-9.
16. Terven J., Córdova-Esparza D. M., Romero-González J. A. A comprehensive review of YOLO architectures in computer vision: From yolov1 to YOLOv8 and YOLO-nas // *Machine learning and knowledge extraction*. 2023. T. 5. № 4. C. 1680–1716. DOI: 10.3390/make5040083.
17. Chen Y., Tang H., Zhou C., Xiong G., Tang H. Weld seam defect detection based on deformable convolutional neural networks // *IEICE Electronics Express*. 2024. Vol. 21. Is. 24. P. 20240468–20240468. DOI: 10.1587/ele.21.20240468.
18. Wen R., Xie W., Fan Y., Shen L. SABE-YOLO: structure-aware and boundary-enhanced YOLO for weld seam instance segmentation // *Journal of Imaging*. 2025. Vol. 11. Is. 8. P. 262. DOI: 10.3390/jimaging11080262.
19. Zong Y., Liu L., Guo D., Zhang H., Shen M. A novel method for segmentation and detection of weld defects in UHV equipment based on multiscale feature fusion // *Russian Journal of Nondestructive Testing*. 2024. Vol. 60. Is. 11. P. 1305–1313. DOI: 10.1134/S1061830924602903.
20. Liu Z., Zhu M., Gao B., Zhao K. YOLO-DC for vehicle detection using deformable convolutional networks and cross-channel coordinate attention // *Scientific Reports*. 2026. URL: <https://www.nature.com/articles/s41598-026-37094-w#citeas> (дата обращения: 05.06.2026). DOI: 10.1038/s41598-026-37094-w.
21. Ai Sh., Li J., Li Y. MDC-YOLO: an enhanced steel plate surface defect detection algorithm based on YOLOv8 // *Engineering Research Express*. 2025. Vol. 7. Is. 4. P. 0452a5. DOI: 10.1088/2631-8695/ae2237.
22. Ковшов Е. Е., Кувшинников В. С. Формирование изображения объекта контроля на гибком детекторе в среде симулятора промышленной радиографии // *Контроль. Диагностика*. 2024. Т. 27. № 3 (309). С. 23–34. URL: <https://elibrary.ru/item.asp?id=65116979> (дата обращения: 05.06.2026). DOI: 10.14489/td.2024.03.pp.023-034.
23. Кувшинников В. С., Ковшов Е. Е. Подготовка специалистов по радиационному виду неразрушающего контроля с применением цифровых технологий // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2023. Т. 13. № 4. С. 54–69. URL: <https://elibrary.ru/item.asp?id=65606784> (дата обращения: 05.06.2026). DOI: 10.21869/2223-1536-2023-13-4-54-69.
24. Кувшинников В. С., Ковшов Е. Е., Сударев А. В. Симуляционная модель промышленного импульсного Ре-источника // *Контроль. Диагностика*. 2026. Т. 29. № 6 (336). С. 24–33. URL: <https://td-j.ru/index.php/current-issue-rus/3848-024-033> (дата обращения: 05.06.2026). DOI: 10.14489/td.2026.06.pp.024-033.
25. ГОСТ 30242-97. Межгосударственный стандарт. Дефекты соединений при сварке металлов плавлением. Классификация, обозначение и определения. М.: ИПК Издательство стандартов, 2001. 36 с.
26. ГОСТ 23055-78. Контроль неразрушающий. Сварка металлов плавлением. Классификация сварных соединений по результатам радиографического контроля. М.: Издательство стандартов, 1992. 8 с.
27. ГОСТ Р ИСО 6520-1-2012. Сварка и родственные процессы. Классификация дефектов геометрии и сплошности в металлических материалах. Ч. 1. Сварка плавлением. М.: Стандартинформ, 2014. 44 с.
28. Ковшов Е. Е., Кувшинников В. С. Виртуализация контроля и оценки радиографических изображений в среде симулятора промышленной радиографии // *Информационные системы и технологии*. 2025. № 4 (150). С. 17–25. URL: <https://elibrary.ru/contents.asp?titleid=82688264> (дата обращения: 05.06.2026).
29. Клейзер М. П., Кувшинников В. С., Ковшов Е. Е. Применение сверточных нейронных сетей при обработке растровых изображений в неразрушающем контроле // *Контроль. Диагностика*. 2024. Т. 27. № 6 (312). С. 60–71. DOI: 10.14489/td.2024.06.pp.060-071. URL: <https://elibrary.ru/item.asp?id=67911241> (дата обращения: 05.06.2026).
30. Сударев А. В., Кувшинников В. С., Ковшов Е. Е. Инструментальные методы и средства автоматизированной оценки качества радиографических изображений в формате DICOM // *Контроль. Диагностика*. 2025. Т. 28. № 12 (330). С. 30–39. URL: <https://elibrary.ru/item.asp?id=84105933> (дата обращения: 05.06.2026). DOI: 10.14489/td.2025.12.pp.030-039.

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.

Финансирование: Авторы заявляют об отсутствии внешнего финансирования.

Financing: The research was performed without external funding.