


Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение
высшего образования
«Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина»
Институт радиоэлектроники и информационных технологий – РТФ
Школа профессионального и академического образования

ДОПУСТИТЬ К ЗАЩИТЕ ПЕРЕД ГЭК

Директор ШПиАО
 Д.В. Денисов
(подпись) (Ф.И.О.)
« 03 » июня 2024 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА

РАЗРАБОТКА СИСТЕМЫ ДЛЯ АВТОМАТИЗИРОВАННОЙ
ОЦЕНКИ КАЧЕСТВА СВАРНЫХ СОЕДИНЕНИЙ ПО РЕЗУЛЬТАТАМ
НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ

Научный руководитель: Ронкин Михаил Владимирович
к.т.н., доцент


подпись

Нормоконтролер: Огуренко Егор Владимирович


подпись

Студент группы: РИМ-220962 Чурилов Алексей Александрович


подпись

Екатеринбург
2024

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение высшего образования
**«Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина»**

Институт радиоэлектроники и информационных технологий – РТФ
Школа профессионального и академического образования
Направление подготовки 09.04.01 Информатика и вычислительная техника
Образовательная программа 09.04.01/33.03 Инженерия машинного обучения

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

студента Чурилова Алексея Александровича группы РИМ-220962
(фамилия, имя, отчество)

1. Тема выпускной квалификационной работы

Разработка системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля

Утверждена распоряжением по институту от «4» декабря 2023 г. № 33.02-05/298

2. Научный руководитель

Ронкин Михаил Владимирович, доцент, к.т.н., доцент

(Ф.И.О., должность, ученая степень, ученое звание)

3. Исходные данные к работе

Набор данных рентгеновских снимков с дефектами, содержит 3272 исходных изображений, включающих шесть типов дефектов сварных соединений


4. Перечень демонстрационных материалов

Рисунки и таблицы для описания основных этапов решения задачи обнаружения дефектов сварных соединений

5. Календарный план

№ п/п	Наименование этапов выполнения работы	Срок выполнения этапов работы	Отметка о выполнении
1.	<i>1 раздел (глава)</i>	до 23.03.2024 г.	✓
2.	<i>2 раздел (глава)</i>	до 29.04.2024 г.	✓
3.	<i>3–4 раздел (глава)</i>	до 20.05.2024 г.	✓
4.	<i>ВКР в целом</i>	до 24.05.2024 г.	✓

Научный руководитель Ронкин Михаил Владимирович
Ф.И.О.


(подпись)

Студент задание принял к исполнению 12.02.24
дата

6. Допустить Чурилова Алексея Александровича к защите выпускной квалификационной работы в экзаменационной комиссии

Директор ШПИАО


(подпись)

Д.В. Денисов
Ф.И.О.

РЕФЕРАТ

Выпускная квалификационная работа содержит 63 страницы., 34 рисунка, 5 таблиц, 24 источника.

Ключевые слова: компьютерное зрение, детектирование дефектов, сверточные нейронные сети, сварные конструкции, неразрушающий контроль.

Объект исследования: процесс создания системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля при помощи компьютерного зрения.

Предмет исследования: создание системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля при помощи компьютерного зрения.

Цель работы: разработка системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля при помощи компьютерного зрения.

В процессе исследования выполнены задачи: проанализированы существующие методы неразрушающего контроля сварных соединений; изучены различные методы и подходы применения технологии компьютерного зрения в промышленном производстве для снижения трудоемкости изготовления сварных конструкций; собрана база данных с основными типами возможных дефектов сварных соединений; разработана система для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля.

Область практического применения: разработанная система может быть использована для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля в условиях реального производственного цикла сварных конструкций.

СОДЕРЖАНИЕ

РЕФЕРАТ	3
СОДЕРЖАНИЕ	4
ПЕРЕЧЕНЬ СОКРАЩЕНИЙ И ОБОЗНАЧЕНИЙ	5
ВВЕДЕНИЕ.....	6
1 Обзор методов CV для НК сварных соединений.....	9
1.1 Процесс сварки.....	9
1.2 Типы дефектов сварных соединений.....	11
1.3 Виды и методы НК сварных соединений.....	14
1.4 Компьютерное зрение	16
1.5 Актуальный опыт использования CV в НК СШ	20
1.6 Выводы по первой главе	27
2 Методология обнаружения дефектов СШ.....	28
2.1 Методы решения задачи	28
2.2 Материалы исследовательской работы	41
2.3 Ход исследовательской работы.....	46
2.4 Выводы по второй главе	48
3 Анализ результатов детектирования дефектов СШ	49
3.1 Визуализация результатов	49
3.2 Оценка результатов	56
3.3 Выводы по третьей главе	59
ЗАКЛЮЧЕНИЕ	60
БИБЛИОГРАФИЧЕСКИЙ СПИСОК	62
ПРИЛОЖЕНИЕ	65

ПЕРЕЧЕНЬ СОКРАЩЕНИЙ И ОБОЗНАЧЕНИЙ

НК	—	неразрушающий контроль
СШ	—	сварной шов
CV	—	компьютерное зрение (computer vision)
CNN	—	сверточная нейронная сеть (convolutional neural network)
DNN	—	глубокая нейронная сеть (deep neural network)

ВВЕДЕНИЕ

В настоящее время компьютерное зрение уже занимает важное место во многих областях промышленности. Используя с камер цифровые изображения и видео, с помощью моделей глубокого обучения, машины могут точно классифицировать и идентифицировать различные объекты и реагировать на это. Но сделать автоматические процессы доступными и в области неразрушающего контроля сварных соединений является все еще сложной задачей.

Применение методов обнаружения объектов с помощью глубокого обучения для обнаружения и идентификации дефектов сварных соединений может эффективно повысить качество контроля и способствовать развитию промышленной автоматизации.

Данное исследование заключается в анализе и сравнении существующих передовых алгоритмов компьютерного зрения, которые было бы эффективно использовать при автоматизированной оценке качества сварных соединений на радиографических изображениях, полученных в результате неразрушающего контроля.

В современном мире промышленность нуждается в автоматизированной проверке и контроле качества выпускаемых товаров. Внедрение современных технологий компьютерного зрения поможет повысить рентабельность бизнеса, снизит человеческие трудозатраты и долю ошибок, допускаемую сотрудниками.

Актуальность данного исследования связана с необходимостью автоматизации и снижения доли ручного труда при оценке качества сварных соединений.

Цель работы заключается в разработке системы, которая может точно и быстро в автоматизированном режиме определять наличие дефекта сварного соединения по результатам неразрушающего контроля, выполнять классификацию дефекта и его локализацию, т.е. определять местоположение дефекта.

Для выполнения поставленной цели необходимо решение следующих задач:

- проанализировать существующие методы неразрушающего контроля сварных соединений;
- изучить различные методы и подходы применения технологии компьютерного зрения в промышленном производстве для снижения трудоемкости изготовления сварных конструкций;
- сформировать базу данных результатов неразрушающего контроля для автоматизированной оценки качества сварных соединений;
- разработать систему для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля.

Объектом исследования выпускной квалификационной работы является процесс создания системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля при помощи технологии машинного обучения – компьютерное зрение.

Предметом исследования является создание системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля при помощи технологии машинного обучения – компьютерное зрение.

Практическая значимость работы заключается в том, что разработанная система может использоваться в промышленном производстве для автоматизации выявления дефектов сварных соединений, упрощая процесс выполнения оценки качества сварных конструкций, по результатам неразрушающего контроля.

Магистерская диссертация включает в себя введение, заключение, список использованных источников и следующие главы:

- обзор методов применения CV для НК сварных соединений;
- методология обнаружения дефектов СШ;
- анализ результатов детектирования дефектов СШ.

1 Обзор методов СВ для НК сварных соединений

1.1 Процесс сварки

Сварка – это процесс получения неразъемных соединений деталей в результате установления межатомных связей между свариваемыми частями при их местном (общем) нагреве или пластическом деформировании, или совместном действии того и другого.

В повышении уровня жизни человека сварка занимает далеко не последнее место. Величественные сооружения прошлого были сделаны из камня (например, Египетские пирамиды), возможно менее величественные, но гораздо более практичные сооружения современности делают из металла (мосты, трубопроводы, атомные электростанции и др.). Потому что человечество научилось резать, обрабатывать и сваривать металлы. Сварка представляет собой один из важнейших процессов в большинстве промышленных отраслей. До 2/3 стального проката в мире идет на производство сварных конструкций [1].

Существует множество различных способов выполнения неразъемных сварочных соединений [2]. Однако, подавляющая часть объема сварочных работ приходится на традиционные способы сварки (плавлением): электродугую (70 ... 80 % от общего объема работ), контактную и газовую.

Использование надлежащей техники и следование передовым практикам позволяет получать сварные соединения с высокими механическими свойствами, как у основного металла свариваемых деталей. Но в процессе выполнения сварных соединений в них могут появляться недопустимые дефекты.

Дефекты сварных соединений — это любое отклонение от заданных нормативными документами параметров сварного соединения, которое образуется вследствие нарушения требований к сварочным материалам, подготовительным работам, сборке и сварке соединяемых

элементов, механической и термической обработке сварных соединений и конструкции в целом [2].

Может сложиться обманчивое впечатление, что появление дефектов при современном уровне развития технологии сварки чрезвычайно редкое или даже невозможное явление. Но дефекты сварных соединений были, есть и будут! А наличие даже маленького дефекта может стать причиной аварии с большим материальным ущербом и человеческими жертвами.

По данным американского общества инженеров-механиков (ASME) причины дефектов сварных соединений распределены следующим образом:

- 45 % – ошибки выбора технологии сварки,
- 32 % – ошибки сварщика,
- 12 % – сбои в работе сварочного оборудования,
- 10 % – неподходящие сварочные материалы,
- 1 % – прочее.

Распределение причин дефектов сварных соединений с помощью круговой диаграммы представлено на рисунке 1.




Рисунок 1 - Причины дефектов сварных соединений

1.2 Типы дефектов сварных соединений

Надежность эксплуатации сварных конструкций зависит от их соответствия нормативно-технической документации, которая регламентирует форму готовых сварных швов, конструктивные размеры, пластичность, прочность, коррозионную стойкость и прочие свойства сварных соединений.

Сварные соединения, выполненные в условиях промышленного производства, могут иметь отступления от заданных размеров, свойств и формы. В процессе эксплуатации изделий эти отступления могут привести к разрушению сварных швов и сварной конструкции. Поэтому каждое такое несоответствие требованиям, установленным нормативной документацией, регламентируется.

С целью выявления причин возникновения дефектов и разработке мероприятий, направленных на устранение этих причин согласно нормативному документу [2] дефекты сварных соединений классифицируются на следующие группы:

- трещины;
- полости, поры;
- включения;
- несплавления и непровары;
- нарушение формы шва;
- прочие дефекты, не включенные в вышеперечисленные группы.

Визуализация дефектов сварных соединений согласно нормативной документации представлена на рисунке 2.




Рисунок 2 - Дефекты сварных соединений

Трещины – нарушение однородности материала, вызванное местным разрушением шва и его охлаждением, либо действием нагрузок; представляют собой макроскопические и микроскопические межкристаллитные разрушения, образующие полости с очень малым начальным раскрытием; под действием остаточных и рабочих напряжений трещины могут расти с большой скоростью. Подобные разрушения происходят очень быстро и представляют собой большую опасность целостности сварной конструкции.

Поры / полости / пористость – нарушение однородности материала, образованное газами, задержанными в расплавленном металле. Обычно поры имеют округлую или трубчатую форму. Они возникают в жидком металле шва в процессе интенсивного газообразования, при котором не все газовые пузырьки успевают подняться на поверхность металла, чтобы выйти в атмосферу. Размеры остающихся в металле пор колеблются от микроскопических, до 2-3 мм в диаметре. В результате диффузии газов поры могут увеличиваться в размерах. В этом случае образуются свищи или

раковины, выходящие на поверхность. Кроме одиночных пор в сварных швах могут появляться цепочки и скопления пор. К основным причинам, вызывающим появление пор, относятся: плохая зачистка свариваемых кромок от масел, ржавчины и различных загрязнений; повышенное содержание углерода в металле конструкции и в присадочном металле.

Включения – разновидности инородных веществ металлического или неметаллического происхождения в металле сварного шва. Включения образуются при загрязнении кромок конструкции, при завышенной скорости сварки, при многопроходной сварке, если плохо зачищены от шлака поверхность предыдущих сварных швов, особенно между слоями. Размеры включений могут достигать нескольких десятков миллиметров по длине шва. Форма их может быть весьма разнообразной, поэтому эти дефекты более опасны, чем поры.

Несплавления и непровары – нарушение однородности материала по всей длине шва или на его отдельном участке, возникающее из-за неспособности расплавленного металла проникнуть внутрь соединения. Несплавленные поверхности могут покрываться тонкими оксидными пленками и другими загрязнениями. Непровары уменьшают рабочее сечение сварного шва, что приводит к снижению работоспособности сварного соединения и конструкции в целом. Подобные дефекты являются концентраторами напряжений и могут вызвать появление трещин, уменьшить коррозионную стойкость сварного соединения и привести к коррозионному растрескиванию.

Нарушение формы шва (подрез) – продольное углубление на наружной поверхности валика сварного шва; подрезы относятся к одним из наиболее часто встречающихся дефектов, чаще всего они образуются при сварке угловых швов в случае смещения электрода или при несколько завышенном напряжении дуги.

1.3 Виды и методы НК сварных соединений

Обнаружение дефектов сварных швов особенно важно для обеспечения целостности, надежности, безопасности и практичности сварных конструкций и изделий. Точная локализация дефектов сварных швов необходима для оценки качества процесса сварки, что повышает производительность, ускоряет выпуск высококачественной продукции и снижает трудозатраты [4]. Для обнаружения дефектов существуют различные виды неразрушающего контроля.

Вид неразрушающего контроля – это условная группировка методов неразрушающего контроля, объединенная общностью физических принципов, на которых они основаны. Методы контроля качества сварных соединений устанавливаются в соответствии с нормативным документом [5]. Неразрушающий контроль в зависимости от физических явлений, положенных в его основу согласно [6], подразделяется на следующие виды:

- оптический;
- радиационный (радиографический);
- акустический;
- магнитный;
- вихретоковый;
- электрический;
- радиоволновой;
- тепловой;
- проникающими веществами.

Одним из наиболее распространенных и сравнительно простых для использования в промышленности методов контроля является радиографический метод, в результате которого получают рентгеновские снимки.

Как указано выше процесс сварки представляет собой один из важнейших процессов в большинстве отраслей отечественной промышленности, но в процессе сварки могут образовываться различные дефекты. Важной задачей является локализация дефектов и их классификация. Особенно выявление недопустимых дефектов актуально для ответственных и очень дорогостоящих сварных конструкций атомной, нефтегазовой, космической промышленности.

Для обнаружения дефектов ранее было разработано множество видов неразрушающего контроля, но в настоящее время традиционные методы контроля сварки полагаются, прежде всего, на опытных специалистов – дефектоскопистов. Дефектоскописты визуально и вручную проверяют сварные швы, а затем экспертно выдают заключение результатов неразрушающего контроля, но это неэффективно, потому что требует значительных финансовых затрат и кропотливого труда человека. Кроме того, усталость человека от длительной работы может снизить точность контроля. [7].

С учетом вышесказанного процесс автоматизации оценки качества по результатам неразрушающего контроля сварных соединений в режиме реального времени является актуальной задачей.

1.4 Компьютерное зрение

Для решения задач, связанных с отказом от утомительного и кропотливого труда человека, могут быть применены решения, основанные на компьютерном зрении.

Компьютерное зрение (computer vision) – это область машинного обучения и компьютерных наук, помогающая вычислительным машинам понимать мир путем распознавания визуальных образов и обнаружения объектов, как это делают люди.

Во многих отношениях задача компьютерного зрения – это задача искусственного интеллекта. Обе дисциплины имитируют биологические процессы, которые основаны на понимании того, как работает мозг человека. Каждая дисциплина двигалась вперед благодаря появлению более совершенных вычислительных ресурсов, развитию искусственных нейронных сетей и больших данных.

Как и другие типы искусственного интеллекта, компьютерное зрение ориентируется на выполнение и автоматизацию задач, имитирующих человеческие возможности. В системах обработки изображений CV используются такие методы, как машинное обучение (machine learning), системы глубокого обучения (DNN) и нейронные сети (neural networks). Эти методы имитируют процесс распознавания и анализа, который проходит в мозге человека. Глубокое обучение – это разновидность машинного обучения, которое использует нейронные сети для решения задач [8].

В последние годы CV, благодаря значительному росту вычислительных возможностей, стало активно использоваться в промышленности, в том числе в таких отраслях, как автомобилестроение, пищевая промышленность, медицина, производство микроэлектроники и многих других. Постоянно появляются новые области применения CV.

В простых системах CV обычно необходимо получить качественную и количественную информацию из изображений: такие параметры, как цвет, размер, количество, характер и направление движения, а также контрастные переходы в окрестностях пикселя изображения, из этих данных производится получение характерных черт. На этих данных далее производится анализ изображения для извлечения полезной информации.

Выделяют следующие ключевые задачи, которые решаются технологиями компьютерного зрения:

- классификация (classification);
- локализация (localization);
- детектирование (detection);
- сегментация (segmentation).

Классификация изображения – процесс присвоения изображению определенного класса; это означает, что компьютер отвечает на вопрос «ЧТО?» изображено и присваивает изображению некий класс из заранее известных классов: поезд, грузовик, каска и др.

Локализация объекта – процесс определения местоположения объекта на изображении; это означает, что компьютер отвечает на вопрос «ГДЕ?» находится объект на изображении.

Детектирование объекта – процесс определения (обнаружения) местоположения объекта и его класса в режиме реального времени; это означает, что компьютер последовательно для объекта на изображении отвечает на вопросы «ГДЕ?» и «ЧТО?».

Сегментация объекта – процесс выделения на изображении интересующего объекта; при описании определяются характерные параметры (например, размеры или форма) необходимые для выделения требуемого объекта на фоне других.

Методы машинного обучения в распознавании образов позволяют компьютерам автоматически извлекать и анализировать информацию для классификации, детектирования или предсказания.

Основными методами машинного обучения, которые применяют в распознавании образов, является глубокая нейронная сеть (DNN), сверточная нейронная сеть (CNN) и предварительно обученные модели нейронных сетей (например, VGG, Xception, ResNet) [9].

Классические полносвязные нейронные сети не годятся для обработки изображений из-за размера изображений и большого количества пикселей. Для обработки такого большого количества информации нужно много нейронов и связей, что делает сеть громоздкой и сложной для обучения. Кроме того, классические нейронные сети не учитывают двумерную структуру изображений, поэтому они не могут корректно запоминать пространственную связь между объектами и их составными частями [8].

Однако для обработки изображений очень хорошо подходят сверточные нейронные сети (CNN), которые появились в 1988 году. Они имеют двумерную структуру, которая аналогична структуре изображений, поэтому анализируют изображение частями, а не целиком, как полносвязные нейронные сети. Это достигается благодаря использованию специальных сверточных слоев, которые уменьшают размер входного сигнала от слоя к слою. Операция свертки представлено на рисунке 3.




Рисунок 3 - Операция свертки

Операция свертки включает перемещение ядра свертки (матрицы-фильтра) по входной матрице, при этом производится матричное умножение участков на ядро свертки входной матрицы. Результат этой операции сохраняется в новую матрицу, которая называется картой признаков [8].

Основные отличительные характеристики CNN представлены ниже:

- является одним из наиболее популярных методов машинного обучения в распознавании образов;
- состоит из нескольких слоев, включает сверточные слои, специальные слои и полносвязный слой;
- имеет в основе успеха операции свертки, в результате которых создается набор уникальных карт признаков образа;
- обучается на большом наборе размеченных изображений и может классифицировать изображения на различные категории.

Существуют два метода обучения нейронных сетей: обучение с учителем (supervised learning) и обучение без учителя (unsupervised learning).

Обучение с учителем предполагает, что машине заранее дают информацию, какой ответ будет считаться правильным. Под учителем здесь понимается обучающая выборка с размеченными нужным образом данными. На основе предоставленных учителем данных машина сама находит и определяет признаки, позволяющие ей принимать решения, например, для классификации изображений.

Обучение без учителя на сегодняшний день является крайне актуальным из-за наличия большого количества неразмеченных, хаотично собранных данных. Машина должна сама найти связи между отдельными данными, выявить закономерности, подобрать шаблоны и отсортировать объекты.

1.5 Актуальный опыт использования CV в НК СШ

В настоящее время компьютерное зрение обеспечивает значительную точность во многих практических приложениях, но сделать автоматические процессы доступными и в области неразрушающего контроля сварных соединений является все еще сложной задачей, однако, в последние несколько лет извлечение, анализ и классификация дефектов сварки на радиографических изображениях получила большое внимание и развитие [10].

Процесс неразрушающего контроля радиографическим методом, который выполняет человек, занимает значительное количество времени. Например, опытному специалисту может потребоваться от 10 до 20 минут, чтобы распознать и заархивировать один кольцевой сварной шов. В случае, например, многокилометрового участка трубопровода этот процесс может потребовать много часов кропотливого труда специалиста [11].


Радиографический метод контроля широко применяется в сварных соединениях, метод основан на преобразовании радиационного изображения контролируемого объекта в радиографический (рентгеновский) снимок.

В основе метода – способность рентгеновских волн проходить через металл. Излучение, которое выходит с противоположной стороны металлической конструкции, может быть измерено. По полученным результатам можно сделать заключение не только о толщине и составе металла, но и о наличии или отсутствии дефектов.

Требования к радиографическому контролю регламентированы нормативным документом [12].

Примеры выявленных дефектов сварных соединений по результатам радиографического контроля представлены на рисунке 4.

Поры



Трещины




Рисунок 4 – Примеры выявленных дефектов сварных соединений по результатам радиографического контроля

Сверточная нейронная сеть (CNN) уже доказала свою эффективность и точность, например при работе с оптическими результатами неразрушающего контроля сварных соединений, но из-за ограниченной доступности конкретных наборов данных, а именно, готовых и размеченных снимков радиографических результатов неразрушающего контроля сварных соединений, обучение CNN для классификации сварочных дефектов не является тривиальной задачей [13]. Однако, даже значительно ограниченный набор данных, как набор рентгеновских изображений сварки, может быть обучен и оценен с высокой точностью; это возможно благодаря расширению данных.

Фактически расширение данных является типичной техникой в любом процессе обучения на большом наборе данных [14]. Кроме того, предлагаются подходы, основанные на использовании предварительно обученных моделей (например, ResNet и др.), которые направлены на классификацию недостатков сварных швов и увеличение количества правильных распознаваний в ограниченном наборе данных.

Подобный подход называется трансферное обучение (transfer learning). Трансферное обучение – это процедура дообучения, которая используется в качестве методологии с предварительно обученной моделью на большом наборе данных (например, AlexNet) [15].

При работе с дефектами сварных соединений наибольший интерес применения компьютерного зрения представляет задача детектирования, которая включает подзадачу локализации дефекта, выделение дефекта с помощью ограничивающих рамок (bounding box), и последующую подзадачу классификации дефекта, определение класса дефекта (трещина, пора, подрез и др.).

Для этого необходимо обучить модель на размеченном наборе данных, выполнить обучение с учителем, чтобы модель могла определять наличие и класс дефектов на новых изображениях сварных соединений.

Исходя из вышеизложенного, для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля можно эффективно использовать задачу детектирования компьютерного зрения. Но сначала необходимо определиться с наилучшим алгоритмом для решения подобной задачи.

Алгоритм обнаружения объектов должен быть реализован с использованием предварительно обученных моделей. Данный способ позволяет экономить время и ресурсы, потому что обучение глубоких нейронных сетей с нуля требует много времени и больших вычислительных ресурсов. Предварительно обученные же модели позволяют существенно

сократить время и ресурсы на обучение, потому что они уже имеют предварительно настроенные веса, обученные на огромных наборах данных. Важно отметить, что это один из способов решить проблему ограниченного количества исходных данных для обучения.

Дополнительно, чтобы эффективно улучшить качество данных и увеличить разнообразие их характеристик, исходные данные будут подвержены процедуре аугментации.

Аугментация данных – это процесс искусственного увеличения количества тренировочных данных с помощью создания измененных копий исходных данных. Цель аугментации – увеличить разнообразие данных, чтобы модель могла обучаться на более разнообразных образцах и лучше обобщать знания на новых данных. При аугментации набор данных подвергается различным геометрическим преобразованиям, при этом изменяется форма и положение объектов на изображении. Не стоит забывать, что существуют методы аугментации, где вносятся изменения в отдельные пиксели изображения. Таким образом набор данных будет увеличен по сравнению с исходными данными с помощью изменения освещенности, случайного поворота, случайного вырезания, добавления гауссовского шума, горизонтального поворота, случайной регулировки насыщенности, контрастности и резкости, случайного изменения размера и случайной обрезки. В результате аугментации эффект переобучения должен быть сведен к минимуму, а качество обучения нейронной сети значительно повыситься.

Далее речь пойдет о методах детектирования объектов. На данный момент выделяют два основных параллельно развивающихся подхода к решению задачи детектирования объектов:

- двухэтапные методы (two-stage methods);
- одноэтапные методы (one-stage methods).

Двухэтапные методы (методы, основанные на регионах) – характерной чертой методов является выделение в них двух основных этапов:

- на первом этапе селективным поиском или с помощью специального слоя нейронной сети выделяются регионы интереса (regions of interest, RoI); это области, с высокой вероятностью содержащие внутри себя объекты;

- на втором этапе выбранные регионы рассматриваются классификатором для определения принадлежности исходным классам и регрессором, уточняющим местоположение ограничивающих рамок.

Одноэтапные методы – подход, не использующий отдельный алгоритм для генерации регионов, вместо этого предсказывающий координаты определенного количества ограничивающих рамок с различными характеристиками, такими, как результаты классификации и степень уверенности, и в дальнейшем корректируя местоположение рамок.

Архитектура Faster R-CNN является передовой из двухэтапных методов. Схема работы Faster R-CNN представлена на рисунке 5.




Рисунок 5 - Схема работы Faster R-CNN

Архитектура Faster R-CNN работает следующим образом:

- изображение подается на вход сверточной нейронной сети для формирования карты признаков;
- карта признаков обрабатывается слоем, который выделяет регионы (region proposal network, RPN); скользящее окно проходится по карте признаков; центр скользящего окна связан с центром якорей (это области, имеющие разные соотношения сторон и разные размеры); в базовой архитектуре используются 3 соотношения сторон и 3 размера; на основе метрики IoF (intersection over union), степени пересечения якорей и истинных размеченных ограничивающих рамок, выносится решение о текущем регионе – есть объект или нет;
- далее используется алгоритм Fast R-CNN, а именно, карта признаков с полученными объектами передаются слою RoI с последующей обработкой полносвязных слоев и классификацией, а также с определением смещения регионов потенциальных объектов.

Архитектура YOLO (you only look once) является передовой из одноэтапных методов и является одним из наиболее популярных для обнаружения объектов методов глубокого обучения [16].

YOLO использует сквозную нейронную сеть, которая делает прогнозы ограничивающих рамок и вероятностей классов одновременно. Благодаря принципиально иному подходу к обнаружению объектов, алгоритм YOLO добился самых значительных результатов и обычно превосходит другие алгоритмы обнаружения объектов в скорости, однако, YOLO может уступать в точности.

С момента первоначального выпуска YOLO в 2015 году было предложено несколько новых версий одной и той же модели, каждая из которых основывалась на своей предшественнице и улучшала ее.

Учитывая, что разрабатываемая система для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля должна работать в режиме реального времени в качестве основной архитектуры будет использоваться YOLO.

В работе планируется применить современный одноступенчатый алгоритм обнаружения объектов YOLO в области обнаружения дефектов сварного шва. При этом планируется сравнить наиболее популярную версию среди пользователей интернет YOLOv5 и последнюю версию YOLOv8 [17]. Согласно информации с официального сайта команды Ultralytics [18] YOLOv8 имеет преимущества по сравнению с предшественниками (YOLOv5 – один из предшественников) и другими моделями обнаружения объектов, а именно, YOLOv8 – это высокая точность; скорость работы в режиме реального времени; эффективность; открытый исходный код.

Предварительные результаты показывают, что применение YOLO для обнаружения дефектов сварного шва может значительно повысить точность, чтобы выполнить задачу множественной классификации и локализации дефектов, но при этом работать в режиме реального времени.

1.6 Выводы по первой главе

В этой главе были введены основные понятия работы: сварные соединения, типы дефектов сварных соединений, виды и методы неразрушающего контроля, машинное обучение, компьютерное зрение.

Рассмотрены актуальные методы и подходы машинного обучения, существующие на сегодняшний день, которые можно использовать для классификации и локализации дефектов сварных соединений. Были показаны преимущества и недостатки использования рассмотренных архитектур машинного обучения. Приведены примеры применения машинного обучения и компьютерного зрения в промышленности, существующие и перспективные области их применения. Также были рассмотрены и проблемы, с которыми сталкиваются создатели моделей машинного зрения.

2 Методология обнаружения дефектов СШ

2.1 Методы решения задачи

Из первой главы известно, что современный одноступенчатый алгоритм обнаружения объектов YOLO хорошо должен подойти для обнаружения и классификации дефектов сварного шва на рентгеновских снимках по результатам неразрушающего контроля сварных соединений. Планируется сравнить наиболее популярную версию среди пользователей интернет YOLOv5 [19] и последнюю версию YOLOv8 [20].

YOLO — это современный алгоритм обнаружения объектов в реальном времени, созданный Джозефом Редмоном, Сантошем Диввалой, Россом Гиршиком и Али Фархади в 2015 году. Алгоритм был предварительно обучен на наборе данных COCO. Он использует одну нейронную сеть для обработки всего изображения. Изображение разбивается на регионы, и алгоритм прогнозирует вероятности и ограничивающие рамки для каждой области.

Обнаружение объектов включает в себя идентификацию и определение местоположения интересующих объектов на изображении или видео. Традиционные методы часто основывались на подходах со скользящим окном, которые были вычислительно затратными и медленными. YOLO использует революционный подход в этой области, потому что рассматривает обнаружение объектов, как одиночную регрессионную задачу [21]. Вместо скользящих окон YOLO предсказывает ограничивающие рамки и вероятности классов для объектов непосредственно из входного изображения за один прямой проход, что значительно ускоряет процесс.

Алгоритм YOLO хорошо известен своей скоростью и точностью и используется во многих приложениях, таких как: здравоохранение, охранное наблюдение, торговля и беспилотные автомобили. С 2015 года команда Ultralytics работает над улучшением этой модели, и с тех пор было выпущено множество версий [18].

Эволюция моделей YOLO представлена на рисунке 6.




Рисунок 6 - Эволюция моделей YOLO

Основной идеей алгоритма YOLO является следующий подход: исходное изображение разбивается сначала на сетку из $N \times N$ ячеек. Если центр объекта попадает внутрь координат ячейки, то эта ячейка считается ответственной за определение параметров для местонахождения объекта. Каждая ячейка изображения описывает несколько различных вариантов местоположения ограничивающих рамок для одного объекта. Каждый из этих вариантов характеризуется пятью следующими значениями – координатами центра ограничивающей рамки (X и Y), его шириной и высотой, а также степенью уверенности, что ограничивающая рамка содержит в себе объект. Также для каждой пары класса объектов и ячейки необходимо определить вероятность того, что ячейка содержит в себе объект именно этого класса. Таким образом, последний слой сети, который принимает конечное решение об ограничивающих рамках и классификации объектов, работает с тензором размерности $N \times N \times (5B + C)$, где B – количество предсказываемых ограничивающих рамок для ячейки, C – количество классов объектов, определенных изначально.

Общая схема работы алгоритма YOLO представлена на рисунке 7.




Рисунок 7 - Общая схема работы алгоритма YOLO

Алгоритм YOLO работает быстрее алгоритмов семейства R-CNN, потому что поддерживает дробление на константное количество ячеек вместо того, чтобы предлагать регионы и рассчитывать решение для каждого отдельного региона. Однако в качестве одной из проблем в алгоритме YOLO указывается сравнительно плохое качество распознавания объектов сложной формы или группы небольших объектов из-за ограниченного числа кандидатов для ограничивающих рамок.

Как указано ранее в результате развития моделей YOLO было выпущено множество различных версий, однако необходимо заметить, что в основе успеха, прежде всего, стоит архитектура одноступенчатых детекторов объектов YOLO. Данная архитектура состоит из трех основных компонентов: backbone, neck, head. Архитектура представлена на рисунке 8.




Рисунок 8 - Архитектура одноступенчатых детекторов объектов

Каждая версия моделей YOLO имеет свои особенности и нововведения в архитектуре, с помощью которых создатели моделей пытались улучшить метрики для решаемых задач. Учитывая, что на практике при выявлении дефектов сварных соединений планируется сравнить только две версии – YOLOv5 и YOLOv8, далее основное внимание будет посвящено особенностям именно этих версий YOLO.

Backbone – это предварительно обученная сверточная нейронная сеть (CNN), отвечающая за извлечение признаков из входного изображения. Backbone помогает уменьшить пространственное разрешение изображения и увеличить его канальное разрешение. YOLOv5 и YOLOv8 используют для backbone пользовательскую нейронную сеть – CSP-Darknet53, а CSP-Darknet53 это сверточная нейронная сеть Darknet53, которая использует сетевую стратегию Cross-Stage Partial (CSP) для преодоления проблемы исчезающего градиента с целью улучшения потока информации между уровнями и повышения точности.

Neck – это экстрактор признаков, который объединяет карты признаков из разных стадий backbone. Экстрактор признаков (Neck) помогает модели лучше обобщать объекты разных размеров и масштабов. YOLOv8 использует новый модуль C2f вместо Feature Pyramid Network (FPN) в YOLOv5 [22]; новый модуль C2f в YOLOv8 сочетает в себе высокоуровневые семантические признаки с низкоуровневой пространственной информацией, что приводит к повышению точности обнаружения, особенно для небольших объектов.

Head используется для выполнения операций заключительного этапа – составление прогнозов. Алгоритм YOLOv5 использует единый модуль обнаружения для предсказания ограничивающих рамок (bounding box) и вероятностей классов. Алгоритм YOLOv8 использует несколько модулей обнаружения, которые предсказывают ограничивающие рамки (bounding box) и вероятности классов для каждой ячейки сетки на карте признаков; затем эти прогнозы объединяются для получения окончательных результатов обнаружения.

Стоит отметить, что версии YOLOv5 и YOLOv8 выпущены в пяти различных размерах для обнаружения объектов. Схематичное представление моделей YOLOv8 представлено на рисунке 9.

Модель n – модель очень маленького (нано) размера.

Модель s – малогабаритная модель.

Модель m – модель среднего размера.

Модель l – крупногабаритная модель.

Модель x – модель очень большого размера.




Рисунок 9 - Схема моделей YOLOv8

Между пятью моделями нет никакой разницы с точки зрения используемых операций, за исключением количества слоев и параметров. При этом YOLOv8 Nano (YOLOv8n) – самый быстрый и маленький, а YOLOv8 Extra Large (YOLOv8x) – самый точный, но самый медленный. Пользователи могут выбрать вариант модели, основанный на компромиссе между точностью и вычислительной эффективностью.

На официальном сайте команды Ultralytics [18] есть сравнительный график производительности YOLOv5 и YOLOv8 на наборе данных COCO (Microsoft Common Objects in Context). Для справки набор данных MS COCO 2017 или просто COCO состоит из 118000 изображений в тренировочной выборке, 5000 изображений в валидационной выборке, 41000 изображений в тестовой выборке. Набор данных содержит 80 классов.

Сравнительный график производительности моделей YOLOv5 и YOLOv8 представлен на рисунке 10.




Рисунок 10 - Сравнение производительности моделей YOLOv5 и YOLOv8

Дополнительно на официальном сайте команды Ultralytics есть таблица с основными показателями работы моделей [18]. Для сравнения основные показатели моделей YOLOv5 и YOLOv8 представлены в таблице 1 и в таблице 2.

Таблица 1 – Основные показатели модели YOLOv5, размер = 640

Модель	mAP ^{val} 50-95	Скорость предсказания на GPU V100 b32, мс	Количество параметров, м	FLOPs	Размер, мб
YOLOv5n	28.0	0.6	1.9	4.5	-
YOLOv5s	37.4	0.9	7.2	16.5	14
YOLOv5m	45.4	1.7	21.2	49	41
YOLOv5l	49.0	2.7	46.5	109.1	89
YOLOv5x	50.7	4.8	86.7	205.7	166

Таблица 2 – Основные показатели модели YOLOv8, размер = 640

Модель	mAP ^{val} 50-95	Скорость предсказания на GPU A100 TensorRT, мс	Количество параметров, м	FLOPs	Размер, мб
YOLOv8n	37.3	0.99	3.2	8.7	-
YOLOv8s	44.9	1.2	11.2	28.6	21
YOLOv8m	50.2	1.83	25.9	78.9	50
YOLOv8l	52.9	2.39	43.7	165.2	84
YOLOv8x	53.9	3.53	68.2	257.8	131

В указанных выше таблицах интересуют показатели точности и скорости работы моделей. Однако необходимо заметить, что результаты тестирования различных моделей YOLOv5 и YOLOv8 были выполнены с использованием различных графических ускорителей (GPU):

- YOLOv5 тестировалась на графическом ускорителе V100 b32, год выпуска GPU V100 – 2017;
- YOLOv8 тестировалась на графическом ускорителе A100 TensorRT, год выпуска GPU A100 – 2020.

Поэтому абсолютные значения скорости предсказания сравнивать некорректно, учитывая, что эти значения получены на вычислительных машинах с различными характеристиками FLOPs.

FLOPS – это количество вычислительных операций или инструкций, выполняемых над операндами с плавающей точкой в секунду. Здесь используется слово «вычислительных», потому что микропроцессор умеет выполнять и другие инструкции с подобными операндами. Такие операции не несут полезной вычислительной нагрузки и поэтому не учитываются.

Согласно информации с официального сайта компании Nvidia GPU NVIDIA V100 является графическим ускорителем с тензорными ядрами, который обеспечивает ускорение нагрузок искусственного интеллекта, анализа данных и высокопроизводительных вычислений (HPC) для решения сложных вычислительных задач. V100 создан на базе архитектуры NVIDIA Volta [23]. Этот графический ускоритель доступен в конфигурациях 16 и 32 Гб и обеспечивает производительность на уровне 32 процессоров.

Согласно информации с официального сайта компании Nvidia GPU NVIDIA A100 является графическим ускорителем с тензорными ядрами, который обеспечивает ускорение нагрузок искусственного интеллекта, анализа данных и высокопроизводительных вычислений (HPC) для решения сложных вычислительных задач. A100 на базе архитектуры NVIDIA Ampere – это ядро платформы NVIDIA для дата-центров [23]. Каждый GPU A100 можно разделить на семь инстансов для быстрой адаптации к постоянно меняющимся запросам. A100 80 Гб обладает быстрой пропускной способностью памяти (более 2 ТБ/с), что позволяет работать с крупными моделями и наборами данных.

Для более удобного сравнения основных показателей моделей YOLOv5 и YOLOv8 данные из таблицы визуализированы с помощью столбчатых диаграмм.

Столбчатая диаграмма сравнения для моделей YOLOv5 и YOLOv8 показателя mAP^{val} представлено на рисунке 11.




Рисунок 11 - Сравнение показателя mAP^{val} 50-95

Столбчатая диаграмма сравнения для моделей YOLOv5 и YOLOv8 показателя скорости предсказания с использованием графического ускорителя GPU представлено на рисунке 12.




Рисунок 12 - Сравнение скорости предсказания на GPU

Столбчатая диаграмма сравнения для моделей YOLOv5 и YOLOv8 показателя количества параметров представлено на рисунке 13.




Рисунок 13 - Сравнение количества параметров

Столбчатая диаграмма сравнения для моделей YOLOv5 и YOLOv8 показателя FLOPs представлено на рисунке 14.




Рисунок 14 - Сравнение FLOPs

Столбчатая диаграмма сравнения для моделей YOLOv5 и YOLOv8 размеров моделей представлено на рисунке 15.




Рисунок 15 - Сравнение размера моделей

Однако сравнение будет не полным без визуального сравнения архитектур нейронной сети для алгоритма, для начала предлагается вспомнить, с чего все начиналось, на рисунке 16 представлена архитектура одной из первых версий YOLO.




Рисунок 16 - Архитектура нейронной сети для алгоритма YOLO

Подробная архитектура с указанием всех слоев сверточной нейронной сети для модели YOLOv5 представлена на рисунке 17. Как указано выше между пятью моделями YOLOv5 нет никакой разницы с точки зрения используемых операций, однако, есть различия в количестве слоев и параметров.




Рисунок 17 - Архитектура YOLOv5

Подробная архитектура с указанием всех слоев сверточной нейронной сети для модели YOLOv8 представлена на рисунке 18. Как указано выше между пятью моделями YOLOv8 нет никакой разницы с точки зрения используемых операций, однако, есть различия в количестве слоев и параметров.




Рисунок 18 - Архитектура YOLOv8

Стратегия обучения YOLOv8 является комплексной; что помогает оптимизировать производительность. Одной из примечательных особенностей является использование нескольких разрешений при обучении, что позволяет модели обучаться на изображениях в разных масштабах. Кроме того, модель использует метод мозаичного дополнения данных, объединяя несколько изображений в один входной сигнал для обучения. Такой подход расширяет возможности модели по обобщению на различные сценарии и повышает ее надежность.

Учитывая массивность и сложность указанных выше архитектур для обучения моделей машинного зрения понадобится графический ускоритель, чтобы не обучать модель вечно на CPU. Поэтому в данной работе используется Colab [24].

Colaboratory (Colab) – это размещенная служба Jupyter Notebook, которая не требует настройки для использования и предоставляет бесплатный доступ к вычислительным ресурсам, включая мощные графические процессоры и тензорные ускорители (TPU). Colab позволяет писать и выполнять код Python в браузере, а также команды Linux. Colab особенно хорошо подходит для машинного обучения.

Выбраны алгоритмы, подготовлены вычислительные мощности, где будут выполняться эксперименты. Далее необходимо определиться с материалами исследовательской работы и метриками качества.

2.2 Материалы исследовательской работы

Общая схема установки компьютерного зрения (системы рентгеновской визуализации в реальном времени), которая использована для сбора набора данных в этой работе, представлена на рисунке 19.




Рисунок 19 - Схема установки компьютерного зрения

Система рентгеновской визуализации результатов неразрушающего контроля сварных соединений состоит из следующих основных элементов:

- движущаяся по производственной линии заготовка, подготовленная для выполнения сварного соединения;
- рентгеновский аппарат;
- цифровой высокоскоростной плоский детектор;
- компьютер для сбора информации.

Рентгеновский аппарат является источником рентгеновского излучения, которое проникает через сварное соединение. Плоский детектор является приемником результатов рентгеновского излучения. Детектор поглощает рентгеновские фотоны, которые проникают через сварное соединение, при этом создавая электронные данные, сохраняющие информацию о фотонах. Далее электронные данные преобразуются в последовательность цифровых изображений, которая затем передается на компьютер для обработки и отображения.

Набор данных состоит из 3272 исходных изображений, включающих шесть типов дефектов сварных соединений. Распределение дефектов сварных соединений по типам представлено на рисунке 20.



Рисунок 20 - Распределение дефектов сварных соединений по типам

Разметка данных для машинного обучения выполнена с использованием специального программного обеспечения «Толока» от компании «Яндекс» для маркировки области дефекта сварного соединения (создание bounding box) и его классификации; разметка данных впоследствии была преобразована в стандартный формат набора данных для обучения с использованием моделей YOLO.

Особенностью набора данных являются следующие наблюдения:

- существенная несбалансированность дефектов по типам;
- изображения с пористостью обычно содержат несколько дефектов, но все дефекты принадлежат одному классу; изображения с остальными типами дефектов обычно содержат единичный дефект.

Примеры размеченных изображений типов дефектов сварных соединений по результатам неразрушающего контроля, а именно пористость, подрез и обрыв дуги представлены на рисунке 21. Примеры изображений взяты из исследуемого набора данных.




Рисунок 21 - Примеры размеченных изображений с дефектами СШ

Примеры размеченных изображений содержащие другие типы дефектов, а именно трещина, нарушение формы и несплавление представлены на рисунке 22.




Рисунок 22 - Примеры размеченных изображений с дефектами СШ

2.3 **Ход исследовательской работы**

Учитывая вышеописанные особенности набора данных, для оценки качества работы алгоритма использованы метрики Precision (точность) и Recall (полнота). Метрики Precision и Recall не зависят от соотношения классов и потому применимы в условиях несбалансированных выборок, в отличие от другой широко применяемой метрики Ассурасу. Дополнительно, для оценки потенциальной возможности применения компьютерного зрения на производстве для обнаружения дефектов сварных соединений, замерено время обнаружения и классификации дефектов на изображениях после обучения на исследуемом наборе данных для следующих предварительно обученных моделей: YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x.

Метрика Precision, также известная как точность, представляет собой инструмент для измерения доли объектов, названных классификатором дефектами и при этом действительно являющимися дефектами в наборе данных. Именно метрика Precision не позволит записывать все дефекты в один класс. Метрика Precision определяется по следующей формуле:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

Метрика Recall, также известная как полнота, представляет собой инструмент для измерения способности модели обнаруживать все положительные срабатывания в наборе данных. Эта метрика имеет особое значение в ситуациях, где пропуск положительного срабатывания может иметь серьезные последствия, например, пропуск дефекта сварного соединения в дорогостоящем оборудовании. Метрика определяется по следующей формуле:

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

В формулах определения метрик Precision и Recall используются следующие условные обозначения:

- TP (True Positive) – это случаи, когда модель правильно определила наличие дефекта сварного соединения, другими словами, это случай, когда дефект действительно есть, и модель правильно положительно сработала;

- FP (False Positive) – это случаи, когда модель ошибочно определила наличие дефекта сварного соединения, при этом дефекта нет;

- FN (False Negative) – это случаи, когда модель ошибочно определила отсутствие дефекта сварного соединения, при этом дефект есть и он пропущен!

Процесс выполнения исследовательской работы представлены схематично на рисунке 23.




Рисунок 23 - Процесс исследовательской работы

Всего можно выделить три основных этапа:

- этап предобработки данных;
- этап обучения модели;
- этап постобработки результатов.

Каждый этап является довольно затратным по времени исполнения. Исходные данные необходимо аккуратно структурировать и предварительно разметить, кроме того было подготовлено множество функций для работы с данными: создание аннотаций изображений; преобразование изображений в формат YOLO; различные функции по визуализации изображений; функции манипуляций с файлами и папками дефектов и многие другие полезные функции, которые играли важные роли при создании системы, которая должна точно и быстро в автоматизированном режиме определять наличие дефекта сварного соединения по результатам неразрушающего контроля. Затем обучение на графических ускорителях, где в зависимости от объема изображений для типа дефекта обучение длилось от нескольких минут до нескольких часов. Заключительный этап – анализ полученных результатов, на основе которых возможно сделать заключение о возможности использования разрабатываемой системы для автоматизации оценки качества сварных соединений по результатам неразрушающего контроля.

2.4 Выводы по второй главе

В этой главе был проведен сравнительный анализ архитектур одноступенчатых детекторов объектов YOLO, которые имеют перспективы применения в режиме реального времени на производстве в разрабатываемой системе для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля. С учетом выбранных методов решения задачи подобраны вычислительные мощности для обучения нейронной сети компьютерного зрения. Описана предварительная, но перспективная схема установки системы компьютерного зрения для сбора данных. Подготовлен базовый набор данных с типовыми дефектами сварных соединений для исследования. Спланирован ход исследовательской работы и выбраны метрики качества для оценки результатов исследования.

3 Анализ результатов детектирования дефектов СШ

3.1 Визуализация результатов

Матрица экспериментов по обнаружению типовых дефектов сварных соединений по результатам неразрушающего контроля при использовании современных инструментов машинного зрения YOLOv5 и YOLOv8 представлена в таблице 3.

Таблица 3 – Матрица экспериментов для различных типов дефектов

Размер модели YOLO	Nano		Small		Medium		Large		XLarge	
Версия YOLO	v5	v8	v5	v8	v5	v8	v5	v8	v5	v8
Пористость	-	-	+	+	+	+	+	+	+	+
Подрез	-	-	+	+	+	+	+	+	+	+
Обрыв дуги	-	-	+	+	+	+	+	+	+	+
Трещина	-	-	+	+	+	+	+	+	+	+
Нарушение формы	-	-	+	+	+	+	+	+	+	+
Несплавление	-	-	+	+	+	+	+	+	+	+

Для обучения с помощью алгоритмов YOLO в Colab был загружен ранее представленный набор данных, на этапе предобработки выполнены следующие операции:

- настройка рабочей среды, а именно, в Colab настроено виртуальное окружение и установлены требуемые для работы библиотеки Python;
- приведение изображений к одному размеру (resize);
- преобразование исходного трехканального (цветного) изображения в одноканальное (черно-белое) изображение с целью

уменьшения матричного представления изображения для ускорения процесса обучения (данная операция не влияет на качество изображения, потому что рентгеновский снимок в любом случае содержит только черно-белые тона);

- разделение набора данных на тренировочную и валидационную выборку;

- создание специально для алгоритмов обучения YOLO иерархической структура папок и файлов, где каждому файлу изображения (*.jpg) с дефектом сварного соединения соответствует файл с его разметкой (*.txt); а в файле разметки указан тип (класс) дефекта и параметры для ограничивающих рамок (bounding box) дефекта - ширина, высота, положение X и Y;

- преобразование разметки в специальный формат YOLO;

- создание файла yaml с типами (классами) дефектов.

Созданная специально для алгоритмов обучения YOLO структура папок и файлов в Colab представлена на рисунке 24.



Рисунок 24 - Структура папок и файлов в Colab

Пример исходных трехканальных изображений представлен на рисунке 25, результат преобразования их в одноканальные изображения представлен на рисунке 26.




Рисунок 25 - Исходные трехканальные изображения




Рисунок 26 - Преобразованные одноканальные изображения

Специальный формат YOLO представлен на рисунке 27.



Рисунок 27 - Специальный формат YOLO

Для обучения моделей YOLOv5 и YOLOv8 для всех типоразмеров были выбраны следующие настройки гиперпараметров:

- img 640;
- batch 16;
- epochs 50.

Остальные настройки YOLOv5 приняты по умолчанию.

На этапе обучения в Colab с использованием графического ускорителя с тензорными ядрами получены модели машинного обучения предназначенные для детектирования и классификации дефектов сварных соединений. В зависимости от объема данных для определенного типа дефекта обучение одной модели длилось от нескольких минут до нескольких часов.

На этапе постобработки выполнена визуализация для более удобного анализа результатов решения задачи детектирования различных типов дефектов в подготовленных моделях компьютерного зрения.

Для различных типов дефектов для сравнения представлены оригинальные снимки, размеченные снимки и снимки с предсказаниями на рисунках 28 - 30.




Рисунок 28 - Дефекты

Оригинальный рентгеновский снимок содержит исходные результаты неразрушающего контроля. Размеченный снимок содержит дополнительно ограничивающие рамки для локализации дефекта по результатам работы дефектоскописта. Снимок с предсказаниями содержит ограничивающие рамки по результатам работы машинного обучения.




Рисунок 29 - Дефекты

Оригинальный рентгеновский снимок содержит исходные результаты неразрушающего контроля. Размеченный снимок содержит дополнительно ограничивающие рамки для локализации дефекта по результатам работы дефектоскописта. Снимок с предсказаниями содержит ограничивающие рамки по результатам работы машинного обучения.




Рисунок 30 - Дефекты

Оригинальный рентгеновский снимок содержит исходные результаты неразрушающего контроля. Размеченный снимок содержит дополнительно ограничивающие рамки для локализации дефекта по результатам работы дефектоскописта. Снимок с предсказаниями содержит ограничивающие рамки по результатам работы машинного обучения.

3.2 Оценка результатов

Выше была представлена визуализация результатов работы моделей машинного обучения. Признаков переобучения не выявлено, потому что значения функции потерь на тренировочных и валидационных данных находятся достаточно близко друг к другу, что говорит о высокой обобщающей способности моделей.

После обучения моделей по детектированию различных типов дефектов для каждой модели были получены метрики Precision и Recall. Для более удобного сравнительного анализа таблицы с метриками, данные визуализированы с помощью столбчатых диаграмм. Метрика Precision и Recall представлены соответственно в таблице 4 и таблице 5

Таблица 5.

Таблица 4 – Метрика Precision

Модель	A	B	C	D	E	F
YOLOv5s	0,651	0,854	0,803	0,872	0,853	0,763
YOLOv5m	0,664	0,863	0,813	0,883	0,863	0,773
YOLOv5l	0,671	0,877	0,825	0,894	0,875	0,797
YOLOv5x	0,675	0,878	0,826	0,896	0,876	0,786
YOLOv8s	0,645	0,844	0,798	0,866	0,845	0,759
YOLOv8m	0,665	0,862	0,813	0,884	0,863	0,773
YOLOv8l	0,673	0,877	0,814	0,892	0,873	0,782
YOLOv8x	0,681	0,882	0,834	0,905	0,881	0,792
A – Пористость; B – Подрез; C - Обрыв дуги; D – Трещина; E - Нарушение формы; F - Несплавление						

Таблица 5 – Метрика Recall

Модель	A	B	C	D	E	F
YOLOv5s	0,601	0,844	0,773	0,857	0,843	0,733
YOLOv5m	0,614	0,853	0,783	0,868	0,853	0,743
YOLOv5l	0,621	0,867	0,795	0,879	0,865	0,767
YOLOv5x	0,625	0,868	0,796	0,881	0,866	0,756
YOLOv8s	0,595	0,834	0,768	0,851	0,835	0,729
YOLOv8m	0,615	0,852	0,783	0,869	0,853	0,743
YOLOv8l	0,623	0,867	0,784	0,877	0,863	0,752
YOLOv8x	0,631	0,872	0,804	0,89	0,871	0,762

А – Пористость; В – Подрез; С - Обрыв дуги; D – Трещина;
Е - Нарушение формы; F - Несплавление

Столбчатая диаграмма метрики Precision по детектированию различных типов дефектов представлена на рисунке 31.




Рисунок 31 - Метрика Precision

Столбчатая диаграмма метрики Recall по детектированию различных типов дефектов представлена на рисунке 32.




Рисунок 32 - Метрика Recall

Показатели метрик получены со сравнительно высокими значениями. Учитывая, что чем ниже значение метрики Precision, тем больше ложных срабатываний, можно сделать вывод, что для снимков, которые содержат тип дефекта пористость, система будет чаще, чем для других дефектов, выдавать дефектоскописту ложную команду, чтобы дефектоскопист более тщательно изучил снимок на наличие дефектов. Однако, перепроверка для дефектоскопии не является критичной.

А вот низкие значения метрики Recall могут иметь гораздо более серьезные последствия, потому что, чем ниже значения Recall, тем больше пропусков дефектов, которые потенциально могут привести к негативным последствиям! Однако, учитывая скученность пор на изображениях в наборе данных полученный результат решения также является полезным в работе дефектоскописта, потому что в среднем каждая вторая пора детектируется, а дефектоскопист по месту уже сможет обнаружить пору, которая находится рядом с распознанной порой, но не была распознана. Пример подобной ситуации, где невыявленный дефект с помощью машинного зрения будет все равно обнаружен дефектоскопистом, потому что модель не среагировала на локальную пору, но тем не менее выдала команду дефектоскописту более тщательно изучить снимок на наличие дефектов, представлено на рисунке 33.




Рисунок 33 – Невыявленный дефект на выявленном снимке

Столбчатая диаграмма скорости работы моделей в детектировании и классификации различных типов дефектов представлена на рисунке 34.




Рисунок 34 – Столбчатая диаграмма скорости работы моделей

По результатам проделанной работы выявлено, что модели YOLOv5 и YOLOv8 различных размеров показали сравнительно близкие результаты. Следовательно, в зависимости от требуемой точности на площадке промышленного производства и возможностей рентгеновской аппаратуры делать снимки сварных конструкций возможно применять различные модели в системе для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля.

Получен опыт использования современных инструментов компьютерного зрения для автоматизации выявления дефектов сварных конструкций. Дальнейшее развитие системы возможно при расширении набора данных по результатам опытного тестирования системы на практике в условиях реального производственного цикла сварных конструкций.

3.3 Выводы по третьей главе

В этой главе подробно описан пул выполненных экспериментов и проведен анализ полученных результатов тестирования современных инструментов компьютерного зрения для решения важной практической задачи по автоматизации оценки качества сварных соединений по результатам неразрушающего контроля.

ЗАКЛЮЧЕНИЕ

Машинное зрение – это область компьютерной науки, которая держит фокус на создании цифровых систем, которые способны обрабатывать, анализировать и понимать визуальные данные так же, как это делает человек. В основе лежит возможность обучить компьютер обрабатывать изображение на уровне пикселей с целью последующего извлечения полезной информации из этих изображений.

Технически компьютер получает визуальную информацию, обрабатывает ее и с помощью специальных программных алгоритмов может интерпретировать полученную информацию. На сегодняшний день компьютерное зрение способно решить самые актуальные проблемы, которые встречаются на производственных площадках, а автоматизация ручного труда всегда актуальна для повышения рентабельности и эффективного любого производства.

Учитывая, что значительная доля стального проката в мире идет на производство сварных конструкций, которые применяются в самых востребованных отраслях промышленности была поставлена цель по разработке системы для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля с использованием современных инструментов компьютерного зрения.

Для достижения поставленной цели были сформулированы и решены следующие задачи:

- проанализированы существующие методы неразрушающего контроля сварных соединений;
- изучены различные методы и подходы применения технологии компьютерного зрения в промышленном производстве для снижения трудоемкости изготовления сварных конструкций;

- собрана база данных с основными типами возможных дефектов сварных соединений;
- разработана система для автоматизированной оценки качества сварных соединений по результатам неразрушающего контроля.

Таким образом все задачи решены, цель работы достигнута. Получен опыт использования современных инструментов компьютерного зрения для автоматизации выявления дефектов сварных конструкций.

Дальнейшее развитие системы возможно при расширении набора данных по результатам опытного тестирования системы на практике в условиях реального производственного цикла сварных конструкций.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Овчинников В.В. Современные виды сварки / В.В.Овчинников. – 5-е изд., стер. – М.: Издательский центр «Академия», 2016. – 208 с.
2. ГОСТ 19521-74. Сварка металлов. Классификация [Текст]: дата введения 1975-01-01. – М.: Госстандарт СССР: Изд-во стандартов, 1978. – 12 с.
3. ГОСТ 30242-97. Дефекты соединений при сварке металлов плавлением. Классификация, обозначение и определения [Текст]: дата введения 2003-01-01. – М.: Межгосударственный стандарт: Изд-во стандартов, 2001. – 8 с.
4. Wafaa Al-Hameed, Prof. Yahya Mayali and Prof. Phil Picton. 2013. Segmentation of radiographic images of weld defect // Journal of Global Research in Computer Science, 2013, pp. Z1–Z2. ISSN-2229-371X
5. ГОСТ 3242-79. Соединения сварные. Методы контроля качества [Текст]: дата введения 1981-01-01. – М.: Межгосударственный стандарт: Изд-во стандартов, 2002. – 10 с.
6. ГОСТ 18353-79. Контроль неразрушающий. Классификация видов и методов [Текст]: дата введения 1980-07-01. – М.: Межгосударственный стандарт: Изд-во стандартов, 2002. – 12 с.
7. J.P. Hui, G.Y. Lian, J.S. Wu. 2023. The weld seam detection method based on the infoCRnet model // ISSN 0543-5846, 2024, pp. Z1–Z2.
8. Michael A. Nielsen. Neural Networks and Deep Learning // Determination Press, 2015. – Z. pp.
9. Ронкин М.В., Акимова Е.Н., Мислов В.Е., Решетников К.И. Обзор применения глубоких нейронных сетей и параллельных архитектур в задачах фрагментации горных пород // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2023. Т. X, № Y, С. Z1–Z2. DOI: 10.14529/cmse230X0Z

10. Wenhui Hou, Lulu Rao, Andong Zhu and Dashan Zhan. Feature Fusion for Weld Defect Classification with Small Dataset // Hindawi. Journal of Sensors, 2022, pp. Z1–Z2. DOI:10.1155/2022/8088202
11. Roman Sizyakin, Viacheslav Voronin, Nikolay Gapon, Aleksandr Zelensky and Aleksandra Pizurica. Automatic detection of welding defects using the convolutional neural network // Conference: Automated Visual Inspection and Machine Vision III, 2019, pp. Z1–Z2. DOI:10.1117/12.2525643
12. ГОСТ 7512-82. Контроль неразрушающий. Соединения сварные. Радиографический метод [Текст]: дата введения 1984-01-01. – М.: Межгосударственный стандарт: Изд-во стандартов, 2004. – 18 с.
13. Benito Totino, Fanny Spagnolo, Stefania Perri. RIAWELC: A Novel Dataset of Radiographic Images for Automatic Weld Defects Classification // Journal of electrical and computer engineering research, 2023, pp. Z1–Z2. DOI:10.53375/ijecer.2023.320
14. Chiraz Ajmi, Juan Zapata, José Javier Martínez-Álvarez, Ginés Doménech, Ramón Ruiz. Using Deep Learning for Defect Classification on a Small Weld X-ray Image Dataset // Journal of Nondestructive Evaluation, 2020, pp. Z1–Z2. DOI:10.1007/s10921-020-00719-9
15. Chiraz Ajmi, Juan Zapata, Sabra Elferchichi, Abderrahmen Zaafouri and Kaouther Laabidi. Deep Learning Technology for Weld Defects Classification Based on Transfer Learning and Activation Features // Hindawi. Advances in Materials Science and Engineering, 2020, pp. Z1–Z2. DOI:10.1155/2020/1574350
16. Girshick, R., Donahue, J., Darrell, T., Malik, J. Rich feature hierarchies for accurate object detection and semantic segmentation // In Proceedings of the IEEE conference on computer vision and pattern recognition, 2014, pp. 580-587.

17. Филичкин С. А., Вологдин С. В. Сравнение эффективности алгоритмов YOLOv5 и YOLOv8 для обнаружения средств индивидуальной защиты человека // Интеллектуальные системы в производстве. 2023. Т. 21, № 3. С. 124–131. DOI: 10.22213/2410-9304-2023-3-124-131
18. Ultralytics YOLOv8. URL: <https://docs.ultralytics.com/> (дата обращения 08.03.2024).
19. Ieamsaard, J., Charoensook, S. N., Yammen, S. Deep learning-based face mask detection using yolov5 // In 2021 9th International Electrical Engineering Congress (iEECON), 2021, pp. 428-431.
20. Yang, G., Feng, W., Jin, J., Lei, Q., Li, X., Gui, G., Wang, W. Face mask recognition system with YOLOv5 based on image recognition // In 2020 IEEE 6th International Conference on Computer and Communications (ICCC), 2020, pp. 1398-1404.
21. Du, Y., Pan, N., Xu, Z., Deng, F., Shen, Y., Kang, H. Pavement distress detection and classification based on YOLO network // International Journal of Pavement Engineering, 2021, pp. 1659-1672. DOI 10.1080/10298436.2020.1714047.
22. Tsung-Yi Lin, Piotr Dollar, Ross Girshick, Kaiming He, Bharath Hariharan, and Serge Belongie. Feature pyramid networks for object detection // In Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp. 2117-2125.
23. Nvidia. URL: <https://www.nvidia.com/> (дата обращения 08.03.2024).
24. Google Colaboratory. URL: <https://colab.google/com> (дата обращения 08.03.2024).

ПРИЛОЖЕНИЕ

Ссылка на набор данных:

<https://drive.google.com/drive/folders/1SXRgjp-WxDx6yAHtEB33pejpO9hyZWqy?usp=sharing>

Ссылка на Colab:

https://drive.google.com/file/d/1mEW6zff24ZTnci07RuUygNFq5CeokeXh/view?usp=drive_link

Ссылка на Github:

<https://github.com/AlekseyChurilov>