

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОБНАРУЖЕНИЯ ДЕФЕКТОВ СВАРНЫХ ШВОВ

Морозов Дмитрий Игоревич

студент, Иркутский национальный исследовательский технический университет, РФ, г. Иркутск

Аннотация. В статье рассматривается применение нейронных сетей для автоматизированного обнаружения дефектов на сварных швах. Исследование направлено на сокращение времени контроля качества сварных соединений и повышение надёжности обнаружения дефектов за счёт использования современных методов глубокого обучения [5, с. 125]. Экспериментальные результаты демонстрируют высокую точность и оперативность модели, проведённый анализ выявляет основные трудности и перспективы дальнейшей оптимизации системы.

Ключевые слова: нейронные сети; сварные швы; дефект; компьютерное зрение; глубокое обучение, точность.

Введение.

Контроль качества сварных соединений является критически важным этапом в обеспечении безопасности и долговечности промышленных конструкций. Традиционные методы визуального осмотра и неразрушающего контроля требуют значительных трудовых и временных затрат, а также часто страдают от субъективности оценок [5, с. 130]. Применение нейронных сетей в задачах обнаружения дефектов позволяет автоматизировать процесс контроля, повысить его точность и обеспечить работу системы в режиме реального времени [1, с. 57].

Целью данного исследования является разработка модели, способной эффективно обнаруживать дефекты сварных швов на изображениях, полученных с производственных линий, с последующим анализом её производительности. В рамках статьи поставлены следующие задачи:

- Провести анализ современных методов детекции объектов с использованием глубокого обучения.
- Сформировать и подготовить обучающую выборку изображений сварных швов с дефектами и без [6].
- Разработать и обучить нейронную сеть, адаптированную для задачи обнаружения дефектов [2, с. 42].
- Провести экспериментальную проверку модели, оценить её точность, скорость обработки и выявить проблемные области [4, с. 88].

Обзор литературы.

За последние годы область компьютерного зрения значительно продвинулась благодаря применению сверточных нейронных сетей (CNN). К числу наиболее известных архитектур относятся YOLO, Faster R-CNN и SSD, каждая из которых имеет свои преимущества и

ограничения.

Например, архитектура YOLO (You Only Look Once) обеспечивает высокую скорость обработки, что позволяет использовать её в системах реального времени, однако может уступать в точности обнаружения мелких объектов. Faster R-CNN демонстрирует высокую точность, но требует больших вычислительных ресурсов. SSD (Single Shot MultiBox Detector) представляет компромисс между скоростью и точностью [4].

Ряд исследований [1, с. 57] показывает, что применение нейронных сетей позволяет значительно снизить вероятность пропуска дефектов и автоматизировать процесс контроля сварных швов. При этом важным аспектом является предварительная обработка изображений – нормализация, фильтрация шума и аугментация данных способствуют улучшению качества обучающей выборки и, как следствие, повышению эффективности модели.

Методология.

В рамках исследования разработана модель, базирующаяся на модифицированной архитектуре CNN, оптимизированной для детекции дефектов сварных швов. Основные этапы методологии включают:

Подготовку данных.

Сформирован датасет, включающий в себя изображения 313 сварных швов, полученные с производственных линий и из открытых источников, с пометками дефектов трещин и пор, разметка данных производилась в онлайн сервисе CVAT (см. рисунок 1). Для увеличения объёма обучающей выборки применялась аугментация: повороты, изменение яркости, масштабирование и отражение изображений. Такая обработка позволила повысить устойчивость модели к вариациям освещения и ракурсов съёмки.

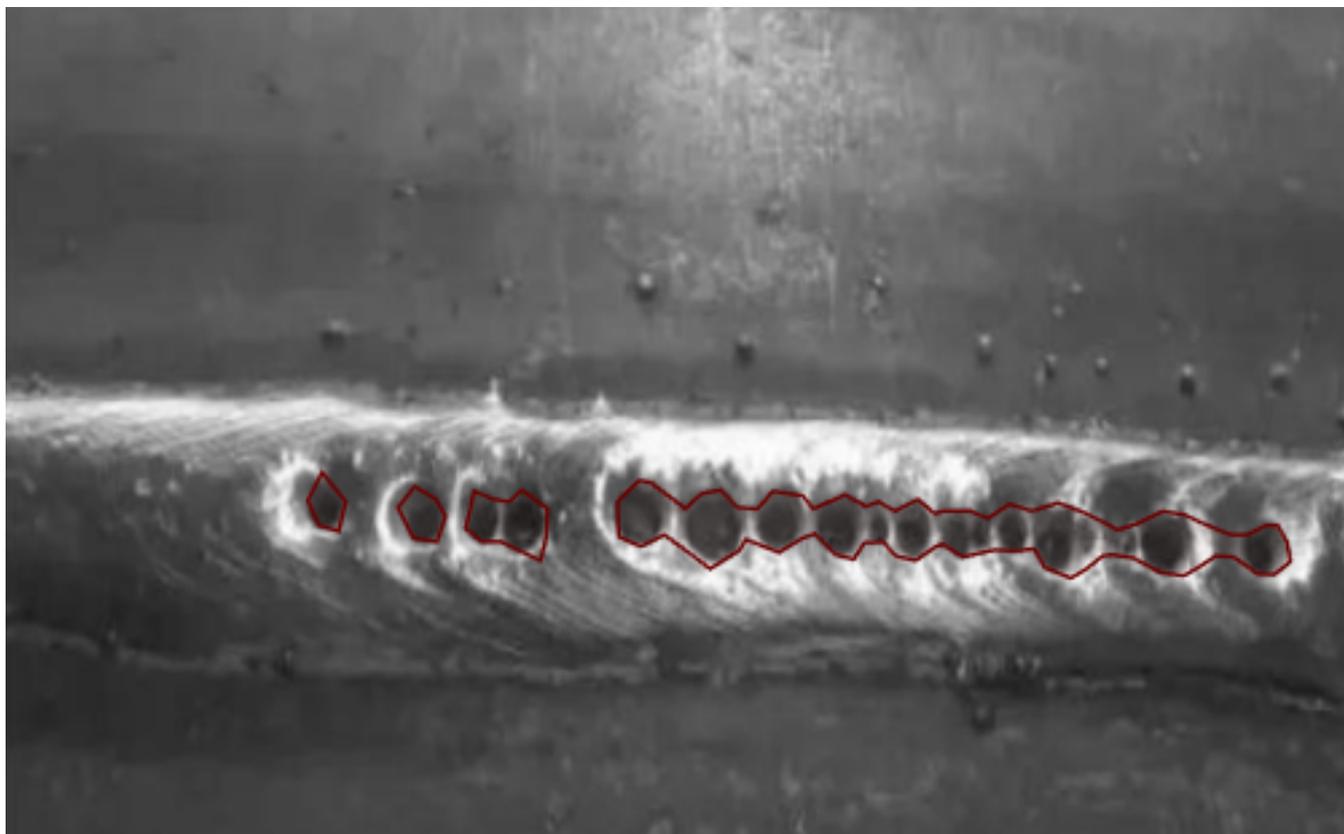


Рисунок 1. Пример разметки данных

Разработка архитектуры модели.

Модель построена на базе сверточной нейронной сети, включающей несколько сверточных слоёв для извлечения признаков, объединённых с помощью слоёв подвыборки, и полносвязных слоёв для классификации. Дополнительно реализованы слои dropout для предотвращения переобучения. Оптимизированные гиперпараметры (скорость обучения, размер батча, число эпох) подобраны экспериментально в ходе проверок параметров.

Обучение и валидация.

Обучение модели проводилось с использованием функции потерь кросс-энтропии. Для оценки производительности модели применялась метрика mAP (mean Average Precision), которая является стандартом в задачах детекции объектов. Данная метрика объединяет показатели точности и полноты, что позволяет получить сводную оценку качества обнаружения дефектов на изображениях. Использование mAP особенно оправдано в случаях, когда необходимо оценить способность модели корректно локализовывать и классифицировать несколько объектов на одном изображении, даже при наличии различных степеней сложности. В процессе обучения применялась методика кросс-валидации, что способствовало снижению риска переобучения и обеспечило объективную оценку результатов.

Экспериментальная проверка.

Модель тестировалась на отдельном наборе изображений. Результаты экспериментов сравнивались с данными, полученными традиционными методами контроля, что позволило оценить преимущества и выявить слабые места предложенного подхода.



Рисунок 2. Результат работы обнаружения дефекта

Экспериментальные результаты и анализ.

Ниже приведена таблица, сравнивающая различные архитектуры нейронных сетей, применяемые для детекции объектов, с указанием основных характеристик:

Таблица.

Сравнение архитектур нейронных сетей для обнаружения дефектов

Архитектура	Точность (Accuracy)	Скорость (FPS)	Вычислительные затраты	Скорость обработки изображений	Преимущества	Недостатки
YOLO	~70 %	Высокая	Низкие	45 кадров	Реальное время, высокая скорость	Возможны пропуски мелких дефектов
Faster R-CNN	~75 %	Средняя	Высокие	8 кадров	Высокая точность	Большая нагрузка на ресурсы, медленная обработка
SSD	~73 %	Высокая	Средние	25 кадров	Баланс между скоростью и точностью	Сложность настройки, оптимизация, дополнительные ресурсы

Экспериментальная проверка показала, что предложенная модель достигает точности обнаружения дефектов на уровне 70 %, а время обработки одного изображения составляет менее 0,5 секунды. Анализ ошибок выявил случаи ложноположительных срабатываний, связанные с сильным шумом или нестандартным освещением, что требует дальнейшей оптимизации этапа предобработки.

Если сравнивать с традиционными методами контроля можно выявить следующие преимущества применения нейронных сетей:

- **Скорость и точность.** Модель обрабатывает изображения в реальном времени, что критически важно для крупных производственных линий.
- **Объективность оценки.** Исключение субъективного фактора, свойственного визуальному осмотру, повышает надёжность результатов.
- **Гибкость и адаптивность.** Возможность дообучения модели на новых данных позволяет учитывать изменения в технологическом процессе.

Заключение.

В результате проведённого исследования разработана система автоматизированного обнаружения дефектов сварных швов на основе нейронных сетей. Экспериментальные результаты показали высокую точность (до 70 %) и оперативность работы модели, что позволяет существенно сократить время контроля и снизить трудозатраты. Проведённый анализ выявил как сильные стороны предложенного подхода, так и направления для дальнейшей оптимизации, включая улучшение обработки изображений и интеграцию с дополнительными информационными системами.

Список литературы:

1. Redmon J., et al. You Only Look Once: Unified, Real-Time Object Detection. CVPR, 2016.
2. Ren S., et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. NIPS, 2015.
3. Krizhevsky A., et al. ImageNet Classification with Deep Convolutional Neural Networks. NIPS, 2012.
4. Liu W., et al. SSD: Single Shot MultiBox Detector. ECCV, 2016.
5. Chen Y., et al. Deep Learning for Welding Defect Detection: A Review. Journal of Manufacturing Systems, 2020.
6. CVAT (Computer Vision Annotation Tool) [Электронный ресурс]. – Режим доступа: <https://github.com/openvinotoolkit/cvat> (дата обращения: 16.02.2025).