

Вестник Череповецкого государственного университета, 2026, № 1 (130), с. 47–65.
Cherepovets State University Bulletin, 2026, no. 1 (130), pp. 47–65.

Научная статья
УДК 004.932.2:004.622
<https://doi.org/10.23859/1994-0637-2026-1-130-4>
<https://elibrary.ru/aznzgi>

Разработка интеллектуальной системы распознавания объектов на рентгеновских снимках сварных соединений

Алексей Леонидович Сотников¹, Роман Владиславович Ковальчик²,
Андрей Андреевич Орлов³✉

¹Донецкий национальный технический университет,
Донецк, Россия

²Приазовский государственный технический университет,
Мариуполь, Россия

³Донбасский государственный технический университет,
Алчевск, Россия

¹0713019870@mail.ru, orcid.org/0000-0002-4537-858X

²kovalchykrv@yandex.ru, orcid.org/0009-0006-5085-804X

³✉ orlov.orlov-andrey193@yandex.ru, orcid.org/0009-0009-3592-168X

Аннотация. Представлены результаты разработанной модели детектирования объектов на рентгеновских снимках сварных соединений с использованием искусственной нейронной сети YOLOv5. Рационально выбранная модель позволила достичь наибольшей точности обнаружения объектов на рентгеновских снимках сварных швов. Подобрана метрика оценки точности работы нейросетевой модели. Обучение модели выполнялось на наборе данных, размеченных с помощью приложения “label-studio”. В результате получена модель, выполняющая детектирование маркировочных знаков на рентгеновских снимках с порогом обнаружения объектов 0,65 и значениями точность-полнота (Precision-Recall) на уровне 0,978. Точность (Precision) распознавания маркировочных знаков составила 97 %. Исследование показало, что предложенная модель может быть использована в программных решениях для автоматизированного радиационного неразрушающего контроля, повышая эффективность и достоверность оценки качества сварных соединений.

Ключевые слова: машинное обучение, компьютерное зрение, нейронные сети, оптимизаторы, маркировочный знак, детектирование объектов, рентгеновский снимок, сварное соединение, радиационный контроль

Для цитирования: 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 (130), с. 47–65. <https://doi.org/10.23859/1994-0637-2026-1-130-4>; EDN: AZNZGI

© Сотников А. Л., Ковальчик Р. В., Орлов А. А., 2026

**Development of an intelligent object recognition system
in X-ray images of welded joints****Aleksey L. Sotnikov¹, Roman V. Kovalchik², Andrey A. Orlov³**¹Donetsk National Technical University,
Donetsk, Russia²Priazovsky State Technical University,
Mariupol, Russia³Donbass State Technical University,
Alchevsk, Russia¹0713019870@mail.ru, orcid.org/0000-0002-4537-858X²kovalchikrv@yandex.ru, orcid.org/0009-0006-5085-804X³orlov.orlov-andrey193@yandex.ru, orcid.org/0009-0009-3592-168X

Abstract. The article presents the results of the developed model for detecting objects in X-ray images of welded joints using the YOLOv5 artificial neural network. A rationally chosen model made it possible to achieve the highest accuracy in detecting objects in X-ray images of welded joints. A metric for assessing the accuracy of the neural network model was selected. The model was trained on a data set labeled using the "label-studio" application. As a result, a model was obtained that detects marking signs in X-ray images with an object detection threshold of 0.65 and Precision-Recall values at the level of 0.978. The accuracy (Precision) of recognizing marking signs was 97 %. The study shows that the proposed model can be used in software solutions for automated radiation non-destructive testing, increasing the efficiency and reliability of assessing the quality of welded joints.

Keywords: machine learning, computer vision, neural networks, optimizers, marking mark, object detection, X-ray, welded joint, radiation monitoring

For citation: Sotnikov A. L., Kovalchik R. V., Orlov A. A. Development of an intelligent object recognition system in X-ray images of welded joints. *Cherepovets State University Bulletin*, 2026, no. 1 (130), pp. 47–65. (In Russ.) <https://doi.org/10.23859/1994-0637-2026-1-130-4>; EDN: AZNZGI

Введение

Контроль качества сварных соединений играет ключевую роль в обеспечении надежности и безопасности металлоконструкций, применяемых в различных отраслях промышленности. В настоящее время для выявления дефектов широко применяются методы неразрушающего контроля (НК)¹. Для идентификации внутренних

¹ Крылова Е. В., Орлов А. А., Пыткина Е. А. Повышение надежности и достоверности обнаружения аномалий и дефектов при тепловом автоматизированном неразрушающем контроле металлических изделий сложной формы и внутренней структуры (на примере лопаток газотурбинных агрегатов) // Тяжелое машиностроение. 2023. № 5–6. С. 17–22; Троицкий В. А. Новые возможности радиационного контроля качества сварных соединений // Автоматическая сварка. 2015. № 7 (743). С. 56–60; Кудояров Р. У., Багин А. С., Могильнер Л. Ю. Повышение выявляемости дефектов сварных швов труб большого диаметра в условиях заводоизготовителей // Наука и технологии трубопроводного транспорта нефти и нефтепродуктов. 2016. № 4 (24). С. 78–83; Маркевич А. В., Полякова М. А., Конищев А. В. О необходимости количественной оценки достоверности определения внутренних дефектов металлопроката // Контроль. Диагностика. 2025. Т. 28, № 2 (320). С. 30–37. <https://doi.org/10.14489/td.2025.02.pp.030-037>; Соловьев А. Н., Соболев Б. В., Васильев П. В.,

несплошностей, как правило, проводится ультразвуковой и радиационный контроль. Радиационный контроль с радиографическим способом получения первичной информации является наиболее информативным, позволяющим визуализировать несплошности сварного соединения, такие как поры, трещины, непровары и др. Интерпретация рентгеновских снимков требует значительного времени и трудозатрат со стороны дефектоскопистов, а с увеличением количества анализируемых снимков вероятность появления ошибок в интерпретации данных возрастает.

Автоматизация процесса обнаружения и классификации дефектов (несплошностей и артефактов) сварных соединений по результатам радиационного НК представляет собой актуальную задачу, решение которой в настоящее время может быть эффективно реализовано с применением искусственных нейронных сетей (ИНС)¹.

В связи с этим активно проводятся исследования по применению технологий искусственного интеллекта (ИИ)², в частности, алгоритмов обработки радиографических цифровых изображений сварных соединений на основе нейросетевого подхода³. Известно большое количество ИНС в различных схемах, обеспечивающих обмен информацией и выдачу результатов даже на основе неполных данных⁴. Благодаря этим свойствам ИНС хорошо подходят для решения задач классификации и обнаружения объектов, в т. ч. при анализе рентгеновских снимков сварных соединений⁵.

Целью данной работы является разработка нейросетевой модели для последующей интеграции в системы цифровой радиографии сварных соединений, что даст

Сеничев А. В., Новикова А. И. Идентификация дефектов в клине с покрытием на основе методов ультразвукового неразрушающего контроля и сверточных нейронных сетей // Вестник ПНИПУ. Механика. 2023. № 1. С. 111–124. <https://doi.org/10.15593/pern.mech/2023.1.11>; Сотников А. Л., Муховатый А. А., Орлов А. А. Классификация методов неразрушающего контроля сварных соединений из меди, полученных сваркой трением с перемешиванием // Сварка и Диагностика. 2022. № 3. С. 19–24. https://doi.org/10.52177/2071-52342022_03_19

¹ Косач А. А., Ковшов Е. Е. Автоматизация обработки данных неразрушающего контроля на основе искусственной нейронной сети // Cloud of Science. 2018. Т. 5. № 3. С. 524–531; Барский А. Б. Нейронные сети: распознавание, управление, принятие решений. Москва: Финансы и статистика. 2004. 176 с. ISBN 5-279-02757-X

² Бадалян В. Г., Вopilкин А. Х. Применение нейронных сетей в ультразвуковом неразрушающем контроле (Обзор) // Контроль. Диагностика. 2022. Т. 25, № 5. С. 12–25. <https://doi.org/10.14489/td.2022.05.pp.012-025>

³ Воробейчиков С. Э., Фокин В. А., Удод В. А., Темник А. К. Оценка эффективности двух алгоритмов сегментации цифрового радиационного изображения объекта контроля // Дефектоскопия. 2017. № 2. С. 60–67; Воробейчиков С. Э., Фокин В. А., Удод В. А., Темник А. К. Исследование двух алгоритмов распознавания образов для классификации дефектов в объекте контроля по его цифровому изображению // Дефектоскопия. 2015. № 10. С. 54–63.

⁴ Тетерин Д. А., Хабибулин Р. Ш., Гудин С. В. Обзор применения искусственных нейронных сетей в управлении социальными и экономическими системами // Научные ведомости. Серия Экономика. Информатика. 2018. Т. 45, № 3. С. 574–583. doi 10.18413/2411-3808-2018-45-3-574-583; Трошестова Д. А., Аbruков В. С. Решение прямых и обратных задач оптики на основе неполных данных // Вестник Чувашского университета. 2013. № 3. С. 63–67.

⁵ Назаренко С. Ю., Удод В. А. Применение искусственных нейронных сетей в радиационном неразрушающем контроле // Дефектоскопия. 2019. № 6. С. 53–64. <https://doi.org/10.1134/S013030821906006X>

возможность повысить уровень оперативности и достоверности обнаружения артефактов на снимках, минимизируя влияние человеческого фактора¹.

Основная часть

1. Разметка данных для обучения искусственной нейронной сети

На первоначальной стадии разработки интеллектуальной системы распознавания объектов на рентгеновских снимках сварных соединений в качестве детектируемого объекта были выбраны маркировочные знаки, которые в обязательном порядке должны присутствовать на рентгеновских снимках для идентификации сварных соединений при проведении НК и документировании полученных результатов. С помощью маркировочных знаков обозначают:

- направление укладки кассет с пленками или рулонной пленки, соответствующее направлению, указанному стрелкой на стыке;
- дату сварки (число, месяц, год);
- шифр (клеймо) сварщика или бригады сварщиков;
- шифр дефектоскописта, осуществляющего просвечивание стыка;
- номер пленки;
- номер стыка;
- участки контроля сварного шва;
- и т. п.

Маркировочные знаки изготавливают из свинца или другого металла, близкого к нему по плотности (рис. 1). Размеры знаков должны соответствовать стандарту ГОСТ 15843-79. На рентгеновских снимках маркировочные знаки имеют характерный вид светлого изображения на темном фоне в негативе (рис. 2).



Рис. 1. Внешний вид маркировочных знаков, изготовленных из свинца



Рис. 2. Варианты внешнего вида маркировочных знаков на рентгеновских снимках

¹ 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.

С целью получения базы данных, на которой выполнялось последующее обучение нейросетевой модели, были использованы 232 рентгеновских снимка с наличием маркировочных знаков различного типа и смыслового содержания (рис. 2). При этом изображение знаков на снимках характеризовалось различным: положением (выше или ниже сварного шва, непосредственно на сварном шве, в центре снимка, с правой или с левой стороны), отображением и ориентацией (зеркальное отражение, вертикальное или горизонтальное написание), размерами, содержанием (буквы английского или русского алфавита, цифры или специальные знаки). Тип рентгеновских снимков также отличался – полученные с помощью цифровой радиографии или традиционной пленочной технологии радиационного контроля. В первом случае – изображения, полученные в цифровом виде, а во втором – результат сканирования рентгеновских пленок с целью их перевода в цифровой вид. Разрешение всех использовавшихся 232 цифровых изображений также варьируется.

Способом разметки данных для обучения нейросетевой модели был выбран bounding box¹, который заключается в выделении детектируемых объектов с помощью прямоугольной рамки, внутри которой находится искомый элемент². Разметка включает в себя определение координат ограничивающей рамки объекта (bounding box) – верхнего левого и нижнего правого углов, а также предсказание класса объекта (рис. 3). Первой цифрой целевого показателя, в данном случае «0», указывается, к какому классу принадлежит детектируемый объект. Классы в данном формате представления выражаются натуральными числами, начиная с нуля. Поскольку в данной задаче стоит цель обнаружения одного класса, который назван “marking mark”, то он отнесен к нулевому классу. Последующие цифры целевого показателя являются координатами двух точек, расположенных по диагонали, которые были получены в процессе разметки изображений с помощью специализированного веб-приложения “label-studio”.

0 0.7502639296187682 0.6952941176470583 0.1646920821114369 0.04941176470588233

а

0 0.3863161764705882 0.3411764705882353 0.07757352941176471 0.12705882352941175
0 0.5003492647058824 0.3388235294117647 0.07291911764705887 0.11764705882352938
0 0.5771470588235293 0.1858823529411765 0.2575441176470587 0.12705882352941175

б

Рис. 3. Представление целевого показателя для обучения нейронной сети для одного (а) и трех (б) объектов на одном рентгеновском снимке

¹ Копылов Д. А., Агешин Е. С., Хомутская О. В. Формирование синтетических данных для обучения системы компьютерного зрения // Автоматизация и моделирование в проектировании и управлении. 2022. № 4 (18). С. 18–28. <https://doi.org/10.30987/2658-6436-2022-4-18-28>

² Lempitsky V., Kohli P, Rother C, Sharp T. Image Segmentation with A Bounding Box Prior. November 2009 Proceedings // IEEE International Conference on Computer Vision. IEEE Xplore. 2009. 9 p. <https://doi.org/10.1109/ICCV.2009.5459262>

Веб-приложение запускается на локальном хосте и имеет удобный графический интерфейс, позволяющий пользователям осуществлять разметку изображений для широкого спектра задач компьютерного зрения. В рассматриваемом случае разметка данных для обучения ИНС выполнялась с использованием в веб-приложении шаблона “Object detection with bounding box” (рис. 4).

Дальнейшая подготовка данных, а также разработка моделей, их обучение, подбор оптимальных гиперпараметров и тестирование выполнялись в среде Google Colaboratory (сокращенно Colab).



Рис. 4. Интерфейс приложения “label-studio” для разметки графических изображений

Colab – это бесплатная облачная среда для совместной работы, разработки и выполнения программного кода на Python непосредственно из браузера. Предоставляет доступ к вычислительным ресурсам, включая графические (GPU) и тензорные (TPU) процессоры, ускоряя процесс вычисления, что делает его популярным инструментом для машинного обучения, анализа данных и других вычислительных задач. Colab основан на Jupyter Notebook, что открывает возможность мгновенно видеть результат выполнения кода и его отдельных частей¹.

Colab доступен через любой браузер, не требует установки дополнительного программного обеспечения и уже имеет в себе предустановленные библиотеки Python для машинного зрения и машинного обучения, таких как TensorFlow, PyTorch, OpenCV, NumPy².

Загрузка исходных данных в проект на Colab и их последующая подготовка реализована с использованием библиотеки gdown. Сами данные, размеченные и импортированные из “label-studio”, были размещены на Google Drive в виде zip архива

¹ Жигулин В. И., Шумилов К. А., Алфимов В. А. Анализ скорости работы и рекомендации при работе с нейронными сетями // Инженерно-строительный вестник Прикаспия. 2023. № 4 (46). С. 92–95. <https://doi.org/10.52684/2312-3702-2023-46-4-92-95>

² Что такое Google Colab и кому он нужен. Skillfactory media. Честные истории о карьере в IT. <https://blog.skillfactory.ru/chto-takoe-google-colaboratory-i-komu-on-nuzhen/> (дата обращения: 05.03.2025).

(рис. 5). В папке архива “images” размещены графические файлы рентгеновских снимков в количестве 232 файла. В папке “labels” – такое же количество текстовых файлов с записью целевого показателя (рис. 3). Имена графических файлов и соответствующих им текстовых файлов идентичны. Файл “classes” содержит наименования детектируемых объектов, а файл “notes” – устанавливает соответствие классов детектируемым объектам. Для загрузки данных в проект и их разархивирования использовался код, приведенный на рис. 6.

Имя	Тип
images	Папка с файлами
labels	Папка с файлами
classes	Текстовый документ
notes	JSON File

Рис. 5. Содержимое zip архива с размеченными данными

```
# Загрузка файла с Google Drive
file_id = '12axGlu0KlQ05gPMLA1pMEj4HWNdqZhqn'
url = f'https://drive.google.com/uc?id={file_id}'
output = 'dataset'
archive = gdown.download(url=url, output=None, fuzzy=True)
# Задание имени рабочего каталога
DATASET_DIR = '/content/dataset'
# Создание рабочего каталога
os.makedirs(DATASET_DIR, exist_ok=True)
shutil.rmtree('sample_data')
# Распаковка архива
shutil.unpack_archive(archive, DATASET_DIR)
print("Архив успешно разархивирован")
# Удаление архива
os.remove(archive)
print("Архив успешно удален")
```

Рис. 6. Код загрузки исходных данных в проект на Colab

Были разработаны сервисные функции для разбиения исходных данных (набора 232 размеченных рентгеновских снимков) на обучающую и тестовую выборки. При этом на обучающие данные отводилось 80 % снимков, а для тестовых данных, призванных осуществлять проверку адекватности моделей, отводилось 20 % от исходного набора данных.

Для проверки правильности разметки и формирования исходных данных с целью последующего обучения ИНС использовалась сервисная функция Colab, которая, используя пути к изображениям, позволяет взять случайное изображение из набора исходных данных и соответствующий ему целевой показатель, соотносящийся с ними метками. В результате функция отображает размеченное изображение и накладывает на него прямоугольные рамки, задаваемые координатами меток, загружен-

ных из целевого показателя. Это позволяет визуально оценить правильность подготовки данных для обучения нейросетевой модели (рис. 7).




Рис. 7. Вывод случайного изображения и результат разметки данных на нем

2. Выбор искусственной нейронной сети

В качестве ИНС для решения поставленной задачи была выбрана нейронная сеть YOLOv5, которая была дообучена на custom dataset (собственной базе данных детектируемых объектов).

YOLO (You Only Look Once) – это семейство ИНС для обнаружения объектов в реальном времени. В отличие от других методов (например, R-CNN), YOLO выполняет обнаружение за один проход по изображению, анализируя его целиком. Это делает YOLO быстрым и эффективным программным решением, что особенно полезно для задач компьютерного зрения, таких как автономное вождение, видеонаблюдение, медицинское и техническое диагностирование, неразрушающий контроль¹.

Поколение ИНС YOLOv5 представляет собой модель для детекции объектов, обладающую высокой скоростью работы и точностью, а самое главное надежностью результатов. YOLOv5 совместим с Google Colab, превосходит предыдущие поколения по производительности, удобству развертывания и точности, а благодаря меньшему размеру, идеально подходит для внедрения в мобильные и встраиваемые устройства.

Архитектура и особенности YOLOv5 представлена несколькими конфигурациями моделей, различающимися числом параметров и вычислительной сложностью:

- YOLOv5s (Small) – самая легковесная модель, оптимальная для работы в условиях ограниченных вычислительных ресурсов;
- YOLOv5m (Medium) – сбалансированный вариант с увеличенным числом параметров;
- YOLOv5l (Large) – более точная модель за счет увеличенного количества слоев и параметров;
- YOLOv5x (Extra Large) – самая мощная версия с максимальной точностью, но высокой вычислительной сложностью.

Каждая из этих моделей представляет компромисс между скоростью обработки изображений и точностью предсказаний.

На начальном этапе исследования в качестве модели была использована конфигурация весов YOLOv5s (Small) с количеством эпох, равным 10, и размером батча, равным 16.

¹ Брекоткин И. А., Рабовская М. Я. Применение нейронной сети для распознавания сварочных дефектов // Молодой ученый. 2024. № 19 (518). С. 9–13.

Оценка качества работы модели детекции объектов выполнялась на основе следующих метрик:

- Precision (Точность) – доля правильно классифицированных объектов среди всех, определенных моделью;
- Recall (Полнота) – доля обнаруженных объектов относительно общего количества объектов в изображении.

Результатом работы моделей являются следующие возможные варианты:

- TP = True Positive: объект действительно есть и модель его правильно обнаруживает;
- TN = True Negative: объект отсутствует и детектор его правильно не находит;
- FP = False Positive: объект отсутствует, но модель ошибочно его детектирует;
- FN = False Negative: объект имеется, но модель ошибочно его не видит.

Точность обнаружения положительного класса характеризуется показателем:

$$Precision = \frac{TP}{TP + FN},$$

где в числителе находится число правильных положительных ответов, а в знаменателе – число всех положительных ответов модели: и верных, и неверных.

Нейронная сеть YOLOv5 использует метрику Intersection over Union (IoU, индекс (расстояние) Жаккара, пересечение над объединением), которая определяется формулой, выраженной в графическом виде на рис. 8.

Параметр «Порог обнаружения объекта» (confidence threshold) в YOLOv5 определяет минимальный уровень уверенности модели в том, что обнаруженный объект действительно присутствует на изображении.




Рис. 8. Метрика Intersection over Union

Конфигурация для нейросети YOLO, в которую входит путь к обучающей и валидационной выборке, количество классов и их наименование, реализован в проекте на Colab в файле “data.yaml” (рис. 9). Детектируемый класс назван “marking mark” (маркировочный знак) и соответствует маркировочным знакам, на которых будет обучаться их определять выбранная ИНС. При помощи данного файла формируется путь к данным, используемым моделями для обучения и валидации полученных результатов. Всего для обучения было использовано 185 изображений и соответству-

ющих им меток объектов, а 47 изображений и их меток использовалось для валидации.

```
data_yaml = """
train: /content/dataset/train/images
val: /content/dataset/val/images

nc: 1
names: ['marking mark']
"""
with open('/content/dataset/data.yaml', 'w') as f:
    f.write(data_yaml)
print("data.yaml file created successfully.")

data.yaml file created successfully.
```

Рис. 9. Код создания файла data.yaml

Для реализации задачи распознавания маркировочных знаков на рентгеновских снимках сварных соединений был использован фреймворк Tensorflow версии 2.17.1, библиотека scikitlearn и библиотека Matplotlib для визуализации результатов обучения моделей. Визуализация обучения необходима для качественной оценки работы моделей и проверки корректности данных на стадии их подготовки к обучению.

3. Результаты обучения искусственной нейронной сети

Полученные результаты обучения ИНС, приведенные на рис. 10 и 11, указывают на то, что нейросетевая модель была недостаточно обученная. Средняя итоговая оценка качества модели по всем изображениям составила $mAP@0.5 = 0,136 = 13,6\%$ (рис. 11). Она учитывает и точность, и полноту распознавания детектируемых объектов. Значение 13,6 % означает, что модель работает плохо на всех изображениях – и почти всегда неправильно определяет разметку.




Рис. 10. Результаты обучения ИНС после обучения модели на 10 эпохах

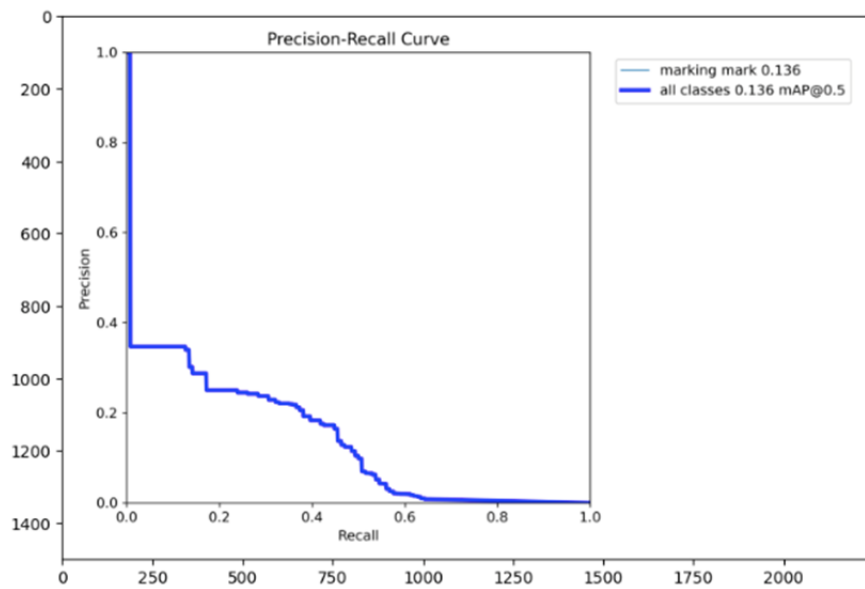


Рис. 11. Кривая Precision-Recall после обучения модели на 10 эпохах

После увеличения количества эпох до 50 и оценки адекватности работы модели при помощи метрик Precision (Точность) и Recall (Полнота) получены результаты,

приведенные на рис. 12 и 13. Порог обнаружения объектов на изображениях (confidence threshold) при этом был увеличен с 0,5 до 0,65.




Рис. 12. Результаты обучения ИНС после обучения модели на 50 эпохах

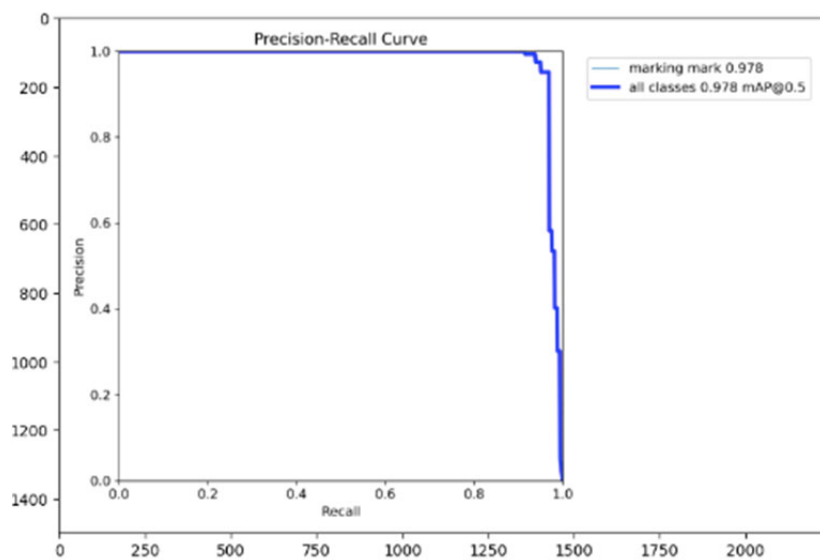


Рис. 13. Кривая Precision-Recall после обучения ИНС на 50 эпохах

Приведенные результаты говорят о том, что полученная модель может быть в принципе использована для автоматической детекции маркировочных знаков на рентгеновских снимках сварных соединений. Средняя итоговая оценка качества модели по всем изображениям составила $mAP@0.5 = 0,978 = 97,8\%$ (“all classes 0,978 $mAP@0.5$ ”) (рис. 13), это означает, что модель стабильно хорошо работает на всех изображениях — и в преобладающем большинстве случаев правильно определяет разметку.

Матрица ошибок (Confusion Matrix) (рис. 10 и 12) визуально иллюстрирует количественную оценку качества работы, полученной в итоге нейросетевой модели, основанной на ИНС YOLOv5, при детекции маркировочных знаков. Горизонтальная ось диаграммы соответствует «Истинному значению» (True), а вертикальная ось «Предсказанному значению» (Predicted), которые в свою очередь разделены на две части: “marking mark” → «маркировочный знак» и “background” → «фон». Получаемые таким образом четыре квадранта соответствуют следующим категориям классификации (рис. 12): истинно-положительным (верхний левый квадрант со значением 0,97, где модель корректно идентифицировала маркировочные знаки), истинно-отрицательным (верхний правый квадрант со значением 1,00), ложноотрицательным (нижний левый квадрант со значением 0,03, где маркировочные знаки были ошибочно классифицированы как фон) и ложноположительным результатам (нижний правый квадрант). В сочетании с высоким значением истинно-положительных результатов (0,97), хороший показатель истинно-отрицательных результатов указывает на сбалансированную модель, которая эффективно распознает как сами маркировочные знаки, так и их отсутствие на снимках.

Высокие значения “True Positives” (TP), а также низкие показатели “False Positives” (FP) и “False Negatives” (FN) свидетельствуют об эффективности модели в распознавании целевых объектов. Низкий уровень FN говорит о высокой надежности детекции даже слабовыраженных или частично скрытых маркировок, что критически важно для промышленного применения, требующего высокой точности контроля качества. Минимальное количество FP показывает, что модель обладает высокой специфичностью, снижая вероятность ложных срабатываний, которые могут привести к ошибкам при автоматизированной инспекции.

Кривая “Precision-Recall Curve” (PR) (рис. 11 и 13) дополнительно подтверждает высокую точность обнаружения объектов. Значение площади под кривой Precision-Recall (AUC-PR), близкое к единице, указывает на отличный баланс между «точностью» (Precision) и «полнотой» (Recall). Значение точности (Precision) на уровне 97% означает, что практически все обнаруженные модели маркировочных знаков действительно являются таковыми, что минимизирует количество ложных детекций. Одновременно с этим, значение полноты (Recall) на уровне 97,8% свидетельствует о том, что модель успешно распознает почти все реально присутствующие маркировочные знаки на изображениях. Такой баланс крайне важен для практического внедрения, поскольку гарантирует, что система детекции не пропустит значимые объекты и не будет генерировать чрезмерное количество ложных срабатываний.

Полученная после обучения в Google Colaboratory модель с наилучшими весовыми коэффициентами сохраняется в файле “best.pt”. Данный файл может быть ис-

пользован в дальнейшем или при разработке самостоятельных программных решений для автоматической детекции артефактов на рентгеновских снимках, или интеграции в системы цифровой радиографии сварных соединений для определения местоположения маркировочных знаков на цифровых снимках.

Для демонстрации работы модели ИНС, полученные веса модели были интегрированы в специализированное веб-приложение, которое выполнено с использованием современного фреймворка FastAPI. Веб-приложение доступно по ссылке [<http://visio.weldmarker.ru>]. Клиентская часть веб-приложения включает пользовательский графический интерфейс, реализованный с использованием HTML, CSS и JavaScript. При загрузке снимков сварных швов и отправки их на сервер выполняется анализ загруженного изображения и детектирование маркировочных знаков при помощи предварительно обученной нейросетевой модели.

В свою очередь, обученная модель имеет следующие параметры, информация о которых отображается при запуске приложения:

“YOLOv5 2025-3-21 Python-3.11.5 torch-2.1.1+cpu CPU” – данная информация указывает на версию YOLOv5, в данной модели – это версия от 21 марта 2025 года, запущенная на Python версии 3.11.5 с использованием фреймворка машинного обучения PyTorch версии 2.1.1 (CPU-версия, без использования GPU);

“Fusing layers...” – означает, что модель выполняет операцию слияния слоев для оптимизации скорости вывода;

“Model summary: 157 layers, 7012822 parameters, 0 gradients, 15.8 GFLOPs” – представляет собой краткую информацию о модели. А именно, модель имеет:

- 157 слоев в архитектуре ИНС;
- 7 012 822 обучаемых параметров;
- 0 градиентов (модель в режиме вывода, а не обучения);
- 15.8 GFLOPs (гигафлопс) – количество операций с плавающей точкой, необходимых для одного прохода;

“Adding AutoShape...” – добавление функциональности AutoShape, которая автоматически обрабатывает входные данные разных форматов.

“2.1.1+cpu” – повторное указание версии PyTorch, используемой для работы модели.

Эти сообщения при запуске приложения указывают на успешную инициализацию модели YOLOv5 для обнаружения объектов с использованием CPU.

Для проверки корректной работы обученной нейросетевой модели были выбраны несколько изображений из тестовой выборки (рис. 14). Как следует из приведенных результатов, ИНС распознает маркировочные знаки с достаточно высокой уверенностью, которая для данных примеров составила в среднем около 85 %, что является хорошим результатом для реализации задач подобного рода.




Рис. 14. Примеры работы нейросетевой модели по обнаружению маркировочных знаков на рентгеновских снимках

Таким образом, предложенная модель детекции на основе YOLOv5 демонстрирует высокую точность и надежность при распознавании маркировочных знаков на рентгеновских снимках сварных соединений. Дальнейшая рационализация, включая тонкую настройку размеров якорных рамок (anchor boxes) и увеличение разнообразия обучающего набора данных, может еще больше повысить качество детекции в условиях изменяющегося качества изображения и контраста, характерных для цифровой радиографии.

Заключение

1. Разработана и обучена ИНС для обнаружения маркировочных знаков на рентгеновских снимках сварных соединений. Модель получена на основе нейросетевой архитектуры YOLOv5 (small). Обучение выполнялось на 50 эпохах с размером батча 16. Модель содержит 157 слоев и 7 012 822 обучаемых параметров.

2. Для оценки адекватности работы модели применялась матрица ошибок Confusion Matrix, использующая метрику Intersection over Union, а также критерий Precision-Recall. Полученные значения точности (Precision) на уровне 97 % и полноты (Recall) на уровне 97,8 % говорят о хороших результатах работы модели по обнаружению маркировочных знаков на рентгеновских снимках.

3. Предложенная модель может быть использована в программных решениях для автоматизированного радиационного НК, с целью повышения эффективности и достоверности оценки качества сварных соединений.

4. Универсальное приложения “label-studio” для разметки графических изображений не позволяет полноценно организовать работу дефектоскопистов по работе с рентгеновскими снимками. Отсутствуют инструменты для обработки снимков, выполнения измерений размеров объектов на них, а также типовая система классифи-

кации детектируемых дефектов и артефактов, что затрудняет проведение совместной работы дефектоскопистов. Все эти обстоятельства обуславливают необходимость разработки специализированной цифровой платформы сбора и разметки данных радиационного неразрушающего контроля сварных соединений с предустановленными классами детектируемых объектов, таких как: маркировочные знаки, дефекты согласно нормативным документам конкретных опасных производственных объектов, эталоны чувствительности, сварные швы, конструктивные элементы сварных соединений, артефакты и т. д.

Список литературы / References

Бадалян В. Г., Вопилкин А. Х. Применение нейронных сетей в ультразвуковом неразрушающем контроле (Обзор). *Контроль. Диагностика*, 2022, т. 25, № 5, с. 12–25.

Badalian V. G., Vopilkin A. Kh. Application of neural networks in ultrasonic non-destructive testing (review). *Testing. Diagnostics*. 2022, vol. 25, no. 5, pp. 12–25. (In Russ.)

Барский А. Б. *Нейронные сети: распознавание, управление, принятие решений*. Москва: Финансы и статистика. 2004. 176 с.

Barskii A. B. *Neural networks: recognition, control, decision making*. Moscow: Finansy i statistika. 2004. 176 p. (In Russ.)

Брекоткин И. А., Рабовская М. Я. Применение нейронной сети для распознавания сварочных дефектов. *Молодой ученый*, 2024, № 19 (518), с. 9–13.

Brekotkin I. A., Rabovskaia M. Ia. Application of a neural network for recognition of welding defects. *Young Scientist*, 2024, no. 19 (518), pp. 9–13. (In Russ.)

Воробейчиков С. Э., Фокин В. А., Удод В. А., Темник А. К. Исследование двух алгоритмов распознавания образов для классификации дефектов в объекте контроля по его цифровому изображению. *Дефектоскопия*, 2015, № 10, с. 54–63.

Vorobeichikov S. E., Fokin V. A., Udod V. A., Temnik A. K. A study of two image recognition algorithms for the classification of flaws in a test object according to its digital image. *Russian Journal of Nondestructive Testing*, 2015, no. 10, pp. 54–63. (In Russ.)

Воробейчиков С. Э., Фокин В. А., Удод В. А., Темник А. К. Оценка эффективности двух алгоритмов сегментации цифрового радиационного изображения объекта контроля. *Дефектоскопия*, 2017, № 2, с. 60–67.

Vorobeichikov S. E., Fokin V. A., Udod V. A., Temnik A. K. Estimating the efficiency of two segmentation algorithms of digital radiation images of test objects. *Russian Journal of Nondestructive Testing*, 2017, no. 2, pp. 60–67. (In Russ.)

Жигулин В. И., Шумилов К. А., Алфимов В. А. Анализ скорости работы и рекомендации при работе с нейронными сетями. *Инженерно-строительный вестник Прикаспия*, 2023, № 4 (46), с. 92–95. <https://doi.org/10.52684/2312-3702-2023-46-4-92-95>

Zhigulin V. I., Shumilov K. A., Alfimov V. A. Speed analysis and recommendations for working with neural networks. *Engineering and Construction Bulletin of the Caspian Region*, 2023, no. 4 (46), pp. 92–95. (In Russ.) <https://doi.org/10.52684/2312-3702-2023-46-4-92-95>

Копылов Д. А., Агешин Е. С., Хомутская О. В. Формирование синтетических данных для обучения системы компьютерного зрения. *Автоматизация и моделирование в проектировании и управлении*, 2022, № 4 (18), с. 18–28. <https://doi.org/10.30987/2658-6436-2022-4-18-28>

Kopylov D. A., Ageshin E. S., Khomutskaya O. V. Forming synthetic data for training a computer vision system. *Automation and Modeling in Design and Management*, 2022, no. 4 (18), pp. 18–28. (In Russ.) <https://doi.org/10.30987/2658-6436-2022-4-18-28>

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.

Korchagin V. D., Kushinnikov V. S., Kovshov E. E. Criterion analysis of radiation nondestructive testing data processing models. *International Journal of Open Information Technologies*, 2024, vol. 12, no. 4, pp. 23–31. (In Russ.)

Косач А. А., Ковшов Е. Е. Автоматизация обработки данных неразрушающего контроля на основе искусственной нейронной сети. *Cloud of Science*, 2018, т. 5, № 3, с. 524–531.

Kosach A. A., Kovshov E. E. Automation of nondestructive testing data processing based on artificial neural network. *Cloud of Science*, 2018, vol. 5, no. 3, pp. 524–531. (In Russ.)

Крылова Е. В., Орлов А. А., Пыткина Е. А. Повышение надежности и достоверности обнаружения аномалий и дефектов при тепловом автоматизированном неразрушающем контроле металлических изделий сложной формы и внутренней структуры (на примере лопаток газотурбинных агрегатов). *Тяжелое машиностроение*, 2023, № 5–6, с. 17–22.

Krylova E. V., Orlov A. A., Pytkina E. A. Improving the reliability and accuracy of detecting anomalies and defects during thermal automated nondestructive testing of metal products of complex shape and internal structure (using the example of gas turbine engine blades). *Heavy Engineering*, 2023, no. 5–6, pp. 17–22. (In Russ.)

Кудояров Р. У., Багин А. С., Могильнер Л. Ю. Повышение выявляемости дефектов сварных швов труб большого диаметра в условиях заводов-изготовителей. *Наука и технологии трубопроводного транспорта нефти и нефтепродуктов*, 2016, № 4 (24), с. 78–83.

Kudoiarov R. U., Bagin A. S., Mogilner L. Yu. Improving detectability of welded joint defects in large pipes at the manufacturing site. *Science & Technologies: Oil and Oil Products Pipeline Transportation*, 2016, no. 4 (24), pp. 78–83. (In Russ.)

Маркевич А. В., Полякова М. А., Конищев А. В. О необходимости количественной оценки достоверности определения внутренних дефектов металлопроката. *Контроль. Диагностика*, 2025, том 28, № 2 (320), с. 30–37. <https://doi.org/10.14489/td.2025.02.pp.030-037>

Markevich A. V., Poliakova M. A., Konishchev A. V. Assessment of the reliability while determining internal defects in metal products. *Testing. Diagnostics*, 2025, vol. 28, no. 2 (320), pp. 30–37. (In Russ.) <https://doi.org/10.14489/td.2025.02.pp.030-037>

Назаренко С. Ю., Удод В. А. Применение искусственных нейронных сетей в радиационном неразрушающем контроле. *Дефектоскопия*, 2019, № 6, с. 53–64. <https://doi.org/10.1134/S013030821906006X>

Nazarenko S. Yu., Udod V. A. Application of artificial neural networks in radiation nondestructive testing. *Russian Journal of Nondestructive Testing*, 2019, no. 6, pp. 53–64. (In Russ.) <https://doi.org/10.1134/S013030821906006X>

Соловьев А. Н., Соболь Б. В., Васильев П. В., Сеничев А. В., Новикова А. И. Идентификация дефектов в клине с покрытием на основе методов ультразвукового неразрушающего контроля и сверточных нейронных сетей. *Вестник ПНИПУ. Механика*, 2023, № 1, с. 111–124. <https://doi.org/10.15593/perm.mech/2023.1.11>

Soloviev A. N., Sobol B. V., Vasiliev P. V., Senichev A. V., Novikova A. I. Identification of defects in a coating wedge based on ultrasonic non-destructive testing methods and convolutional neural networks. *PNRPU Mechanics Bulletin. Mechanics*, 2023, no. 1, pp. 111–124. (In Russ.) <https://doi.org/10.15593/perm.mech/2023.1.11>

Сотников А. Л., Муховатый А. А., Орлов А. А. Классификация методов неразрушающего контроля сварных соединений из меди, полученных сваркой трением с перемешиванием. *Сварка и Диагностика*, 2022, № 3, с. 19–24. https://doi.org/10.52177/2071-52342022_03_19

Sotnikov A. L., Mukhovaty A. A., Orlov A. A. Classification of nondestructive testing methods for copper welds obtained by friction stirring. *Welding and Diagnostics*, 2022, no. 3, pp. 19–24. (In Russ.) https://doi.org/10.52177/2071-52342022_03_19

Тетерин Д. А., Хабибулин Р. Ш., Гудин С. В. Обзор применения искусственных нейронных сетей в управлении социальными и экономическими системами. *Научные ведомости. Серия: Экономика. Информатика*, 2018, т. 45, № 3, с. 574–583. <https://doi.org/10.18413/2411-3808-2018-45-3-574-583>

Teterin D. A., Khabibulin R. Sh., Gudin S. V. Review of application of artificial neural networks in the management of social and economic systems. *Belgorod State University. Scientific Bulletin. Series: Economics. Information technologies*, 2018, vol. 45, no. 3, pp. 574–583. (In Russ.) <https://doi.org/10.18413/2411-3808-2018-45-3-574-583>

Троешестова Д. А., Аbruков В. С. Решение прямых и обратных задач оптики на основе неполных данных. *Вестник Чувашского университета*, 2013, № 3, с. 63–67.

Troeshestova D. A., Abruikov V. S. Solution of direct and inverse problems of optics on incomplete data. *Bulletin of Chuvash University*, 2013, no. 3, pp. 63–67. (In Russ.)

Троицкий В. А. Новые возможности радиационного контроля качества сварных соединений. *Автоматическая сварка*, 2015, № 7 (743), с. 56–60.

Troitskii V. A. New possibilities of radiation quality control of welded joints. *Automatic welding*, 2015, no. 7 (743), pp. 56–60. (In Russ.)

Что такое Google Colab и кому он нужен. Skillfactory media. Честные истории о карьере в IT. URL: <https://blog.skillfactory.ru/chto-takoe-google-colaboratory-i-komu-on-nuzhen/> (дата обращения: 05.03.2025).

What is Google Colab and Who Needs It. Skillfactory media. Honest IT career stories. Available at: <https://blog.skillfactory.ru/chto-takoe-google-colaboratory-i-komu-on-nuzhen/> (accessed: 05.03.2025). (In Russ.)

Lempitsky V., Kohli P, Rother C, Sharp T. Image Segmentation with a Bounding Box Prior. November 2009 Proceedings. *IEEE International Conference on Computer Vision. IEEE Xplore*. 2009. 9 p. <https://doi.org/10.1109/ICCV.2009.5459262>

Сведения об авторах

Алексей Леонидович Сотников – доктор технических наук, профессор; <https://orcid.org/0000-0002-4537-858X>, 0713019870@mail.ru, Донецкий национальный технический университет (д. 58, ул. Артема, 283001 Донецк, Россия); **Aleksey L. Sotnikov** – Doctor of Technical Sciences, Professor, <https://orcid.org/0000-0002-4537-858X>, 0713019870@mail.ru, Donetsk National Technical University (58, Artema ul., 283001 Donetsk, Russia).

Роман Владиславович Ковальчик – кандидат технических наук, доцент; <https://orcid.org/0009-0006-5085-804X>, kovalchykrv@yandex.ru, Приазовский государственный технический университет (д. 7, ул. Университетская, Мариуполь, Россия); **Roman V. Kovalchik** – Candidate of Technical Sciences, Associate Professor, <https://orcid.org/0009-0006-5085-804X>, kovalchykrv@yandex.ru, Priazovsky State Technical University (7, Universitetskaya ul., Mariupol, Russia).

Андрей Андреевич Орлов – старший преподаватель; <https://orcid.org/0009-0009-3592-168X>, orlov.orlov-andrey193@yandex.ru, Донбасский государственный технический университет (д. 16, пр-кт Ленина, 294204 Алчевск, Россия); **Andrey A. Orlov** – Senior Lecturer, <https://orcid.org/0009-0009-3592-168X>, orlov.orlov-andrey193@yandex.ru, Donbass State Technical University (16, Lenin pr., 294204 Alchevsk, Russia).

Заявленный вклад авторов: Сотников А. Л. – разработка концепции, написание текста статьи, проведение экспериментов; Ковальчик Р. В. – техническое сопровождение и экспертное консультирование при планировании, проведении и анализе результатов экспериментов; Орлов А. А. – научное исследование и аналитический анализ существующих решений, группирование результатов, техническое редактирование текста статьи. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: Sotnikov A. L. – concept development, article text writing, conducting experiments; Kovalchik R. V. – technical support and expert consulting during the planning, execution, and analysis of experiment results; Orlov A. A. – scientific research and analytical review of existing solutions, clustering analysis, technical editing of the article text. The authors declare no conflicts of interests.

Статья поступила в редакцию 31.10.2025; одобрена после рецензирования 12.12.2025; принята к публикации 14.01.2026.

The article was submitted 31.10.2025; Approved after reviewing 12.12.2025; Accepted for publication 14.01.2026.