

УДК 656.073

YOLOv11 для радиографического неразрушающего контроля сварных соединений

Брехт Эдуард Александрович

— аспирант кафедры «Наземные транспортно-технологические комплексы». Научные интересы: нейронные сети, компьютерное зрение, неразрушающий контроль. E-mail: ed.breht@mail.ru

Коншина Вера Николаевна

— канд. техн. наук, доцент кафедры «Наземные транспортно-технологические комплексы». Научные интересы: методы неразрушающего контроля, статистический анализ, достоверность контроля. E-mail: vera.konshina@gmail.com

Петербургский государственный университет путей сообщения Императора Александра I, Россия, 190031, Санкт-Петербург, Московский пр., 9

Для цитирования: Брехт Э. А., Коншина В. Н. YOLOv11 для радиографического неразрушающего контроля сварных соединений // Интеллектуальные технологии на транспорте. 2026. № 1 (45). С. 23–32. DOI: 10.20295/2413-2527-2026-145-23-32

Аннотация. Представлено исследование о применении модели нейронной сети YOLOv11 при радиографическом контроле. **Цель:** обоснование возможности применения YOLOv11 для автоматического обнаружения и визуализации дефектов на рентгенографических снимках сварных соединений. **Методы:** анализ современных инструментов и технологий, включая нейронные сети, а также представительные выборки порядка 100 размеченных изображений с различными типами дефектов и индикаторами качества изображения, дополненная аугментацией и предварительной фильтрацией снимков. **Результаты:** показано, что за счет использования усовершенствованного Backbone с модулями C3k2 и блока пространственного внимания C2PSA модель обеспечивает высокие значения показателей mAP@0,5–0,95 и уверенно распознает как крупные, так и слабоконтрастные малые дефекты при приемлемом времени обработки одного изображения. **Практическая значимость:** состоит в возможности интеграции YOLOv11 в действующие системы неразрушающего контроля сварных швов.

Ключевые слова: нейронная сеть, рентгенографический контроль, дефектограммы, распознавание

1.2.1 — искусственный интеллект и машинное обучение (технические науки)

Введение

В настоящее время задачи неразрушающего контроля сварных соединений все чаще решаются методами компьютерного зрения на основе сверточных нейронных сетей, в том числе моделями архитектуры YOLO [1]. Целью статьи является демонстрация применения модели YOLOv11 для автоматического обнаружения дефектов и индикаторов качества изображения (ИКИ) на рентгеновских снимках сварных швов, а также сравнение ее характеристик с предыдущими версиями [2, 3].

Архитектура YOLO

Модели YOLOv11 сохраняют классическую одношаговую схему распознавания, но используют усовершенствованный Backbone и Neck [1], включающие блоки C3k2 и модуль C2PSA с пространственным вниманием (рис. 1). Это позволяет эффективнее выделять тонкие структуры и слабоконтрастные области, что особенно важно при анализе рентгенограмм с малозаметными протяженными дефектами [4].

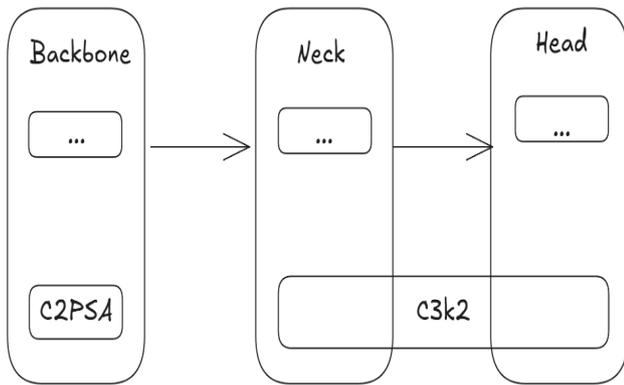


Рис. 1. Общая схема размещения модифицированных модулей в слоях нейронной сети YOLO

В контексте представленной схемы Backbone можно понимать как «зрительную систему» модели: он последовательно преобразует исходное изображение в набор все более абстрактных признаков, а завершающий его модуль C2PSA учится расставлять акценты внутри этих карт признаков, усиливая именно те участки, где могут скрываться дефекты металла. Neck выступает связующим звеном между Backbone и Head (головой модели): он собирает признаки разных масштабов и прогоняет их через блоки C3k2, которые, как умные фильтры, отбрасывают лишний шум и подчеркивают важные контуры, делая будущие рамки объектов более устойчивыми даже при низком контрасте снимка.

Наконец, Head работает уже с очищенными и обогащенными признаками и для каждой обла-

сти изображения выдает понятные человеку результаты: координаты рамки, класс обнаруженного дефекта и степень уверенности модели. В практическом плане это означает, что для инженера-дефектоскописта сложная внутренняя архитектура YOLO11 сводится к более надежному обнаружению длинных трещин и непроваров на рентгенограммах без необходимости ручного поиска едва заметных артефактов [5].

Существенной особенностью современной архитектуры YOLOv11 является многомасштабная обработка изображений: Backbone и Neck формируют несколько уровней карт признаков с разным пространственным разрешением, а Head одновременно анализирует их для поиска как крупных, так и очень мелких объектов. Такая организация особенно важна для рентгенографического контроля сварных швов, где на одном снимке присутствуют и протяженные зоны непровара, и точечные поры, а разница в их размерах может составлять порядок и более [5]. За счет улучшенного слияния признаков в Neck и использования модулей внимания, модель лучше «видит» слабоконтрастные дефекты, не теряя при этом контекст.

Далее рассмотрим, как указанные нововведения повлияли на работоспособность в сравнении с более старыми версиями (рис. 2) [2].

По сравнению с YOLOv8 вариант YOLOv11 достигает более высокой средней точности на на-

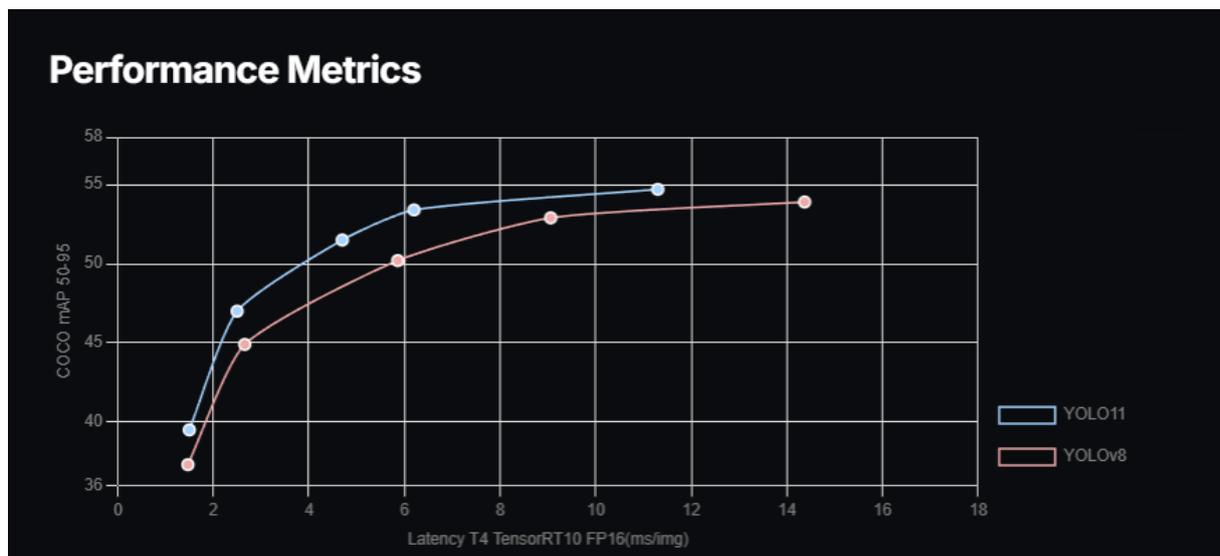


Рис. 2. Сравнение эффективности нейронных сетей

боре COCO (набор данных для сравнения эффективности) при снижении числа параметров [6] примерно на 22%, что упрощает развертывание на вычислительно ограниченных системах. Модель поддерживает единый интерфейс для задач распознавания, сегментации и ориентированных ограничивающих прямоугольников, что позволяет при необходимости расширять систему контроля.

Из недостатков можно отметить некоторое увеличение вычислительной нагрузки по сравнению с более ранними версиями архитектуры. В частности, дополнительные модули внимания требуют большего числа операций, что приводит к увеличению времени обработки одного изображения на тех же программно-аппаратных ресурсах. При развертывании в условиях ограниченных вычислительных мощностей (например, на рабочих станциях дефектоскопистов без специализированных ускорителей) данный фактор необходимо учитывать при выборе варианта модели и настроек решения входных рентгенограмм.

Математическая постановка задачи

Рассматривается задача обнаружения на изображении множества объектов (дефектов сварного шва и ИКИ), для каждого из которых требуется определить класс c и координаты ограничивающего прямоугольника $b = (x, y, w, h)$ в нормированных координатах изображения.

Модель YOLO11 аппроксимирует неизвестное отображение:

$$I \rightarrow \{(b_i, c_i, s_i)\}_{i=1}^N,$$

где I — входное изображение, N — количество обнаруженных объектов, $s_i \in [0, 1]$ — степень уверенности в наличии объекта данного класса.

Качество предсказанного прямоугольника оценивается при помощи метрики пересечения-объединения (Intersection over Union, IoU) для предсказанного бокса B_p и истинного бокса B_t :

$$\text{IoU}(B_p, B_t) = \frac{|B_p \cap B_t|}{|B_p \cup B_t|}.$$

В современных реализациях YOLO для регрессии координат используется модифицированная

IoU-функция потерь, например, CIoU, которая дополнительно учитывает расстояние между центрами прямоугольников и различие их сторон; это позволяет быстрее и точнее подстраивать рамки к дефектам сварного шва.

Общая функция потерь при обучении модели YOLOv11 может быть представлена в виде суммы четырех слагаемых:

$$\mathcal{L} = \lambda_{\text{box}} \mathcal{L}_{\text{box}} + \lambda_{\text{cls}} \mathcal{L}_{\text{cls}} + \lambda_{\text{obj}} \mathcal{L}_{\text{obj}} + \lambda_{\text{DFL}} \mathcal{L}_{\text{DFL}},$$

где \mathcal{L}_{box} отвечает за точность координат боксов (на основе IoU/CIoU), \mathcal{L}_{cls} и \mathcal{L}_{obj} — за правильность класса и факт наличия объекта, а \mathcal{L}_{DFL} (Distribution Focal Loss) уточняет положение границ, обучая модель предсказывать распределение вероятностей по дискретным позициям для каждой координаты. Такая комбинация особенно полезна при работе с рентгенограммами, где границы дефектов размыты, а небольшое смещение рамки приводит к заметному падению IoU [7].

После получения набора «сырых предсказаний» $\{(b_i, c_i, s_i)\}$ на каждом уровне признаков применяется процедура подавления немаксимумов (Non-Maximum Suppression, NMS). Алгоритм последовательно выбирает бокс с максимальным значением s_i , оставляет его как итоговое обнаружение и удаляет все боксы того же класса, для которых IoU с выбранным боксом превышает заданный порог τ . В результате множество перекрывающихся рамок над одним и тем же дефектом сводится к одной наиболее надежной, что упрощает последующую интерпретацию результатов дефектоскопистом.

Для оценки качества распознавания дефектов используются стандартные метрики точности (Precision), полноты (Recall) и средней точности (mean Average Precision, mAP) [7]. Пусть TP — число правильно обнаруженных дефектов, FP — число ложных срабатываний, а FN — число пропущенных дефектов; тогда:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}.$$

Точность показывает, какая доля всех выданных моделью срабатываний действительно соответствует реальным дефектам (важно для снижения

числа лишних проверок), а полнота отражает, какая доля существующих дефектов была найдена (критично с точки зрения безопасности эксплуатации сварных соединений). При варьировании порога уверенности модели строится кривая «точность — полнота» (Precision–Recall curve), по площади под которой вычисляется величина Average Precision (AP) для каждого класса объектов [7]. Подобная кривая соотношения между вероятностью правильного обнаружения и вероятностью перебраковки применялась ранее при оценке достоверности результатов НК (ROC-анализ) [8]. Средняя по всем классам величина mAP определяется как

$$mAP = \frac{1}{C} \sum_{c=1}^C AP_c,$$

где C — число классов, AP_c — средняя точность для класса c .

В статье основное внимание уделяется значениям $mAP@0,5$ и $mAP@0,5-0,95$, рассчитываемым при различных порогах пересечения рамок по IoU.

Описанная постановка задачи и структура функции потерь реализуются в рамках модели YOLOv11, обучаемой на размеченных рентгеновских изображениях сварных соединений. Ниже приведены используемые в работе данные и принятая методика обучения модели на этих изображениях.

Материалы и методика исследования

Для обучения и тестирования модели YOLOv11 использовалась выборка рентгеновских изображений сварных швов, включающая как реально обнаруженные дефекты (рис. 3–4) [9], так и заведомо бездефектные участки. На каждом снимке вручную размечались ограничивающие прямоугольники для дефектов различных типов (поры, непровары, трещины и др. [5]), а также для ИКИ, что позволяло одновременно контролировать качество экспозиции и корректность работы алгоритма.

Выборка была разделена на обучающее, валидационное и тестовое подмножества в пропорциях, обеспечивающих достаточное количество примеров каждого типа дефекта в тренировке

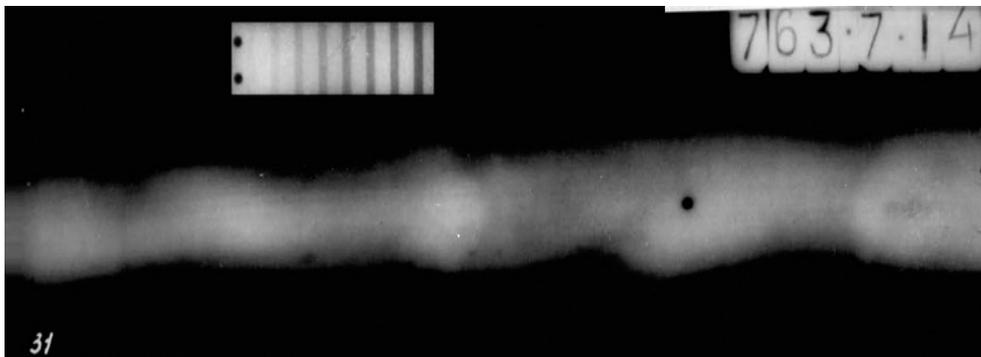


Рис. 3. Пример радиографического снимка с дефектом

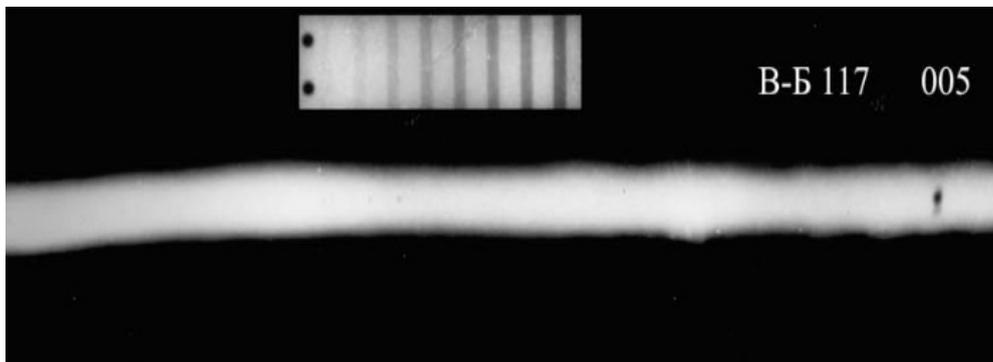


Рис. 4. Пример радиографического снимка без дефекта

и независимой проверке. Изображения нормировались по размеру (например, до 640×640 пикселей) и проходили стандартные аугментации — повороты, сдвиги и изменения яркости/контраста в пределах, не искажающих физический смысл рентгенограммы.

Для уменьшения влияния артефактов рентгенографической пленки предварительно выполнялась фильтрация изображений: удаление границ пленки и служебных меток, легкое сглаживание высокочастотного шума, а также выравнивание гистограммы яркости в области шва. При разметке дополнительно фиксировались случаи частичного перекрытия дефектов и участки с неоднородной толщиной металла, что позволяло в дальнейшем отдельно анализировать работу модели на наиболее сложных примерах.

Для обучения использовалась модель YOLOv11m, реализованная в библиотеке Ultralytics, с размером входного изображения 640×640 пикселей и размером пачки 16 (количество изображений за один проход), выбранным исходя из объема доступной видеопамати (как правило, 8–16 изображений на шаг). Обучение проводилось в течение 50 эпох с оптимизатором SGD или AdamW, начальному уровню обучения назначался порядок 10^{-3}

с косинусным или степенным уменьшением, а лучшие веса выбирались по максимальному значению $mAP@0,5$ на валидационной выборке.

В процессе тренировки использовались встроенные в фреймворк аугментации YOLOv11 (масштабирование, случайные сдвиги и горизонтальные отражения), дополненные ограниченной фотометрической перестройкой яркости и контраста, адаптированной под специфику рентгенограмм. Для предотвращения переобучения применялись ранняя остановка по плато валидационной ошибки и L2-регуляризация весов, что позволило сохранить обобщающую способность модели при сравнительно небольшом объеме данных.

Результаты обучения модели

Качество работы модели оценивалось как по интегральным метрикам (Precision, Recall, $mAP@0,5$, $mAP@0,5-0,95$), так и по динамике отдельных компонент функции потерь на обучающей и валидационной выборках.

На рис. 5 показана динамика обучения модели YOLOv11: в верхнем ряду приведены значения функции потерь по координатам боксов, классам и DFL-компоненте для обучающей выборки, а также рост точности и полноты распознавания

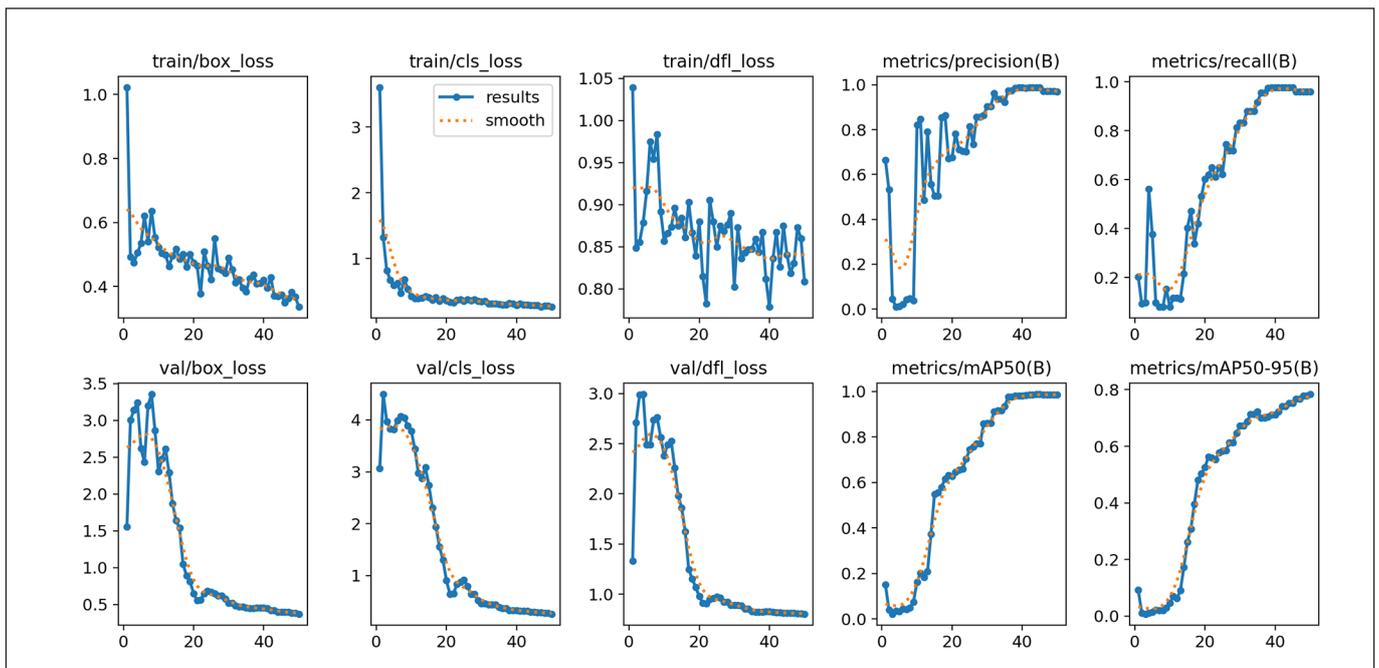


Рис. 5. Графики с основными метриками качества обученной модели

по эпохам. Постепенное снижение всех трех видов потерь и одновременное увеличение Precision и Recall свидетельствуют о том, что модель последовательно улучшает как положение рамок, так и отнесение их к правильному классу дефектов без признаков «развала» обучения.

Нижний ряд иллюстрирует поведение тех же показателей на валидационной выборке: после начального периода колебаний величины box-, cls- и DFL-потерь устойчиво уменьшаются, а метрики mAP@0,5 и mAP@0,5–0,95 монотонно растут и выходят на плато к концу обучения. Это говорит о хорошем согласовании модели с невидимыми ранее данными и отсутствии существенного переобучения, что особенно важно для задач неразрушающего контроля, где необходимо надежно обобщать результаты на новые рентгенограммы сварных соединений.

С практической точки зрения важен не только рост интегральных метрик, но и визуальное поведение модели на отдельных рентгеновских снимках. При выбранных параметрах обучения YOLOv11 уверенно обнаруживает как протяжен-

ные зоны непровара, так и мелкие поры, корректно отделяя их от фоновых неоднородностей и артефактов пленки; при этом границы рамок хорошо совпадают с экспертной разметкой, что подтверждается высокими значениями mAP@0,5–0,95.

На рис. 6 приведен пример работы разработанной нейронной сети по распознаванию дефекта (пора размером $3 \times 2,5$ мм) и ИКИ на рентгеновском снимке. Видно, что модель уверенно идентифицирует оба объекта и формирует для них точные ограничивающие рамки, корректно отделяя дефект от фоновых неоднородностей и артефактов пленки.

Ниже представлен еще один пример работы нейронной сети, иллюстрирующий ее поведение на рентгенограмме с крупным дефектом и ИКИ. На рис. 7 видно, что модель корректно выделяет ИКИ и дефект (шлаковое включение размером 7×5 мм). Формирует устойчивые ограничивающие рамки даже при значительной протяженности дефектной области.

Для того чтобы окончательно убедиться в эффективности работы нейронной сети, далее рассматри-

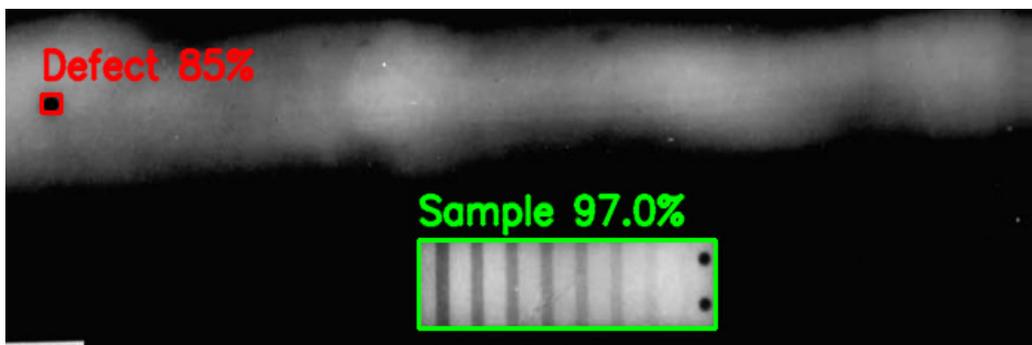


Рис. 6. Пример распознавания дефекта и ИКИ

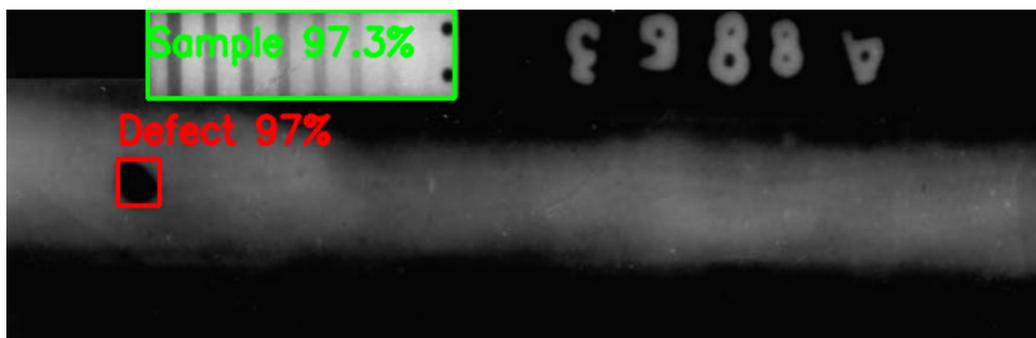


Рис. 7. Пример распознавания крупного дефекта и ИКИ

вается пример небольшого дефекта с пониженным контрастом относительно основного металла (дефект типа «пора» диаметром 1,5 мм). На рис. 8 представлено исходное радиографическое изображение с едва заметным дефектом, а на рис. 9 — результат работы модели, демонстрирующий уверенное распознавание как дефекта, так и ИКИ при сохранении точного позиционирования рамок.

Как видно из рисунков 6–9, обученная модель надежно обнаруживает дефекты различных размеров и контрастности, что снижает риск пропуска опасных нарушений сплошности при приемлемом количестве ложных срабатываний. В условиях реальной эксплуатации это позволяет использовать YOLOv11 как инструмент первичного автоматизированного скрининга рентгенограмм с последующим подтверждением результатов оператором, разгружая дефектоскописта от монотонного просмотра большого числа снимков.

Отдельно стоит подчеркнуть, что даже на малой выборке из порядка 100 изображений YOLOv11 демонстрирует заметный прирост качества по сравнению с более ранними версиями архитекту-

ры, используемыми в предыдущих работах [10]: достигается более высокая полнота при сопоставимой точности, а время обработки одного снимка остается достаточным для применения в режиме, близком к реальному времени. Это позволяет рассматривать данную модель как базу для дальнейшего наращивания датасета и внедрения дополнительных улучшений, например ориентированных рамок или сегментации контуров дефектов [11].

С точки зрения пользователя системы неразрушающего контроля ключевым параметром является вероятность пропуска опасного дефекта при допустимом количестве ложных срабатываний [12]. Высокие значения полноты и mAP при умеренной величине функции потерь при валидации показывают, что YOLOv11 надежно выявляет большинство дефектов даже при обучении на ограниченном числе рентгенограмм, что снижает риск недобраковки или перебраковки объектов контроля.

В то же время форма кривых Precision и Recall позволяет подобрать такие пороги уверенности и параметры NMS, при которых число «лишних» рамок остается приемлемым для дефектоскописта

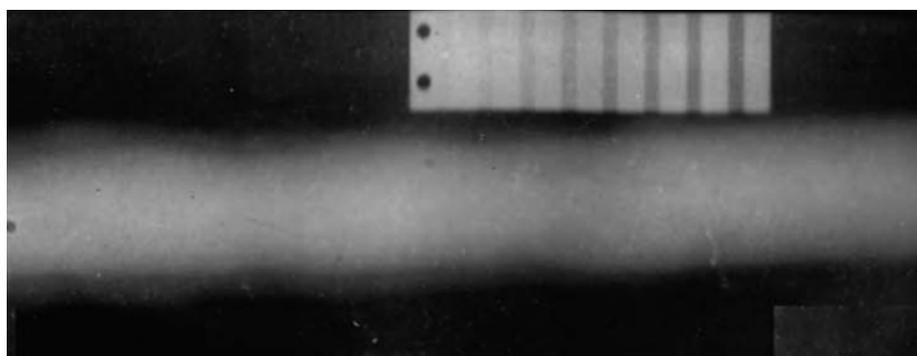


Рис. 8. Пример радиографического изображения с дефектом типа «пора» диаметром 1,5 мм

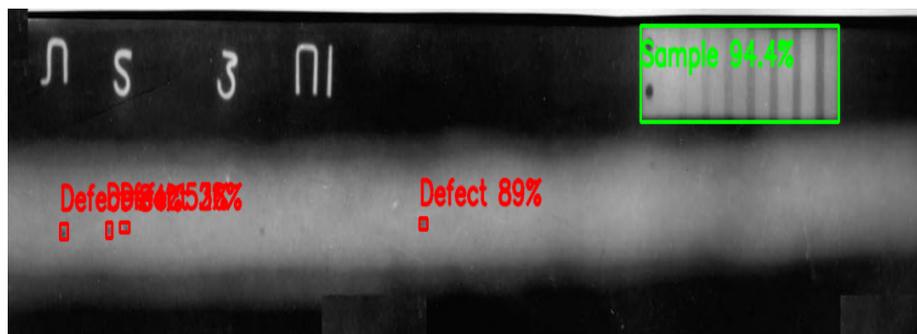


Рис. 9. Пример распознавания небольшого дефекта и ИКИ

и не перегружает интерфейс системы. Это дает возможность адаптировать модель под разные сценарии применения: от максимально чувствительного первичного скрининга до более жесткого режима подтверждения дефектов перед оформлением заключения.

Заключение

Выполненные эксперименты показали, что модель YOLOv11 с усовершенствованным Backbone, включающим модули C3k2 и блок пространственного внимания C2PSA, обеспечивает высокое качество автоматического обнаружения дефектов на рентгеновских снимках сварных соединений даже при обучении на относительно небольшой выборке — порядка 100 изображений. Это выражается в устойчивом снижении значений функций потерь на обучающей и валидационной выборках, росте метрик mAP@0,5–0,95 и высокой согласованности предсказаний с экспертной разметкой, что подтверждает пригодность модели для использования в задачах практического неразрушающего контроля.

Полученные результаты свидетельствуют о том, что YOLOv11 способна надежно обнаруживать как протяженные зоны, так и малые сла-

боконтрастные дефекты при приемлемом времени обработки одного рентгеновского снимка. Это позволяет рассматривать разработанную модель как основу для интеграции в существующие рабочие места дефектоскопистов в качестве модуля автоматизированного первичного скрининга, а также для последующего анализа архивных изображений с целью повышения полноты выявления опасных дефектов.

Перспективными направлениями дальнейшей работы являются расширение объема обучающих данных за счет включения новых типов сварных соединений и режимов рентгенографического контроля, а также адаптация архитектуры под специализированные задачи: использование ориентированных ограничивающих прямоугольников для более точного описания протяженных трещин, внедрение сегментации контуров дефектов и комбинирование YOLOv11 с методами статистического анализа для выработки автоматизированных критериев браковки. Дополнительным шагом может стать исследование производительности облегченных вариантов модели на ограниченных вычислительных платформах, применяемых в промышленных системах.

СПИСОК ИСТОЧНИКОВ

1. Khanam R., Hussain M. YOLOv11: An Overview of the Key Architectural Enhancements // ArXiv. 2024. Vol. 2410.17725. 9 p. DOI: 10.48550/arXiv.2410.17725.
2. Ultralytics YOLO11. URL: <http://docs.ultralytics.com/models/yolo11> (дата обращения: 01.12.2025).
3. Ultralytics YOLO11. Model Card. URL: <http://huggingface.co/Ultralytics/YOLO11> (дата обращения: 01.12.2025).
4. Research on Object Detection and Recognition in Remote Sensing Images Based on YOLOv11 / L.-H. He [et al.] // Scientific Reports. 2025. Vol. 15. Art. 14032. 25 p. DOI: 10.1038/s41598-025-96314-x.
5. Кретов Е. Ф. Ультразвуковая дефектоскопия в энергомашиностроении. 4 е изд., перераб. СПб.: СВЕН, 2014. 312 с.
6. Kotthapalli M., Ravipati D., Bhatia R. YOLOv1 to YOLOv11: A Comprehensive Survey of Real-Time Object Detection Innovations and Challenges // ArXiv. 2025. Vol. 2508.02067. 13 p. DOI: 10.48550/arXiv.2508.02067.
7. Maity A., Ghosh T. Comparative Analysis of Object Detection Algorithms for Surface Defect Detection // ArXiv. 2025. Vol. 2510.21811. 14 p. DOI: 10.48550/arXiv.2510.21811.
8. Применение показателей достоверности для валидации методик неразрушающего контроля / Г. Я. Дымкин, В. Н. Коншина, К. Нокеманн, Г.-Р. Тиллак // Дефектоскопия. 2000. № 3. С. 75–84.
9. ГОСТ 7512–82. Контроль неразрушающий. Соединения сварные. Радиографический метод = Nondestructive testing. Welded joints. Radiography method: межгосударственный стандарт: введен в действие постановлением Государственного комитета СССР по стандартам от 20 декабря 1982 г. № 4923: дата введения: 1984-01-01. М.: Стандартинформ, 2008. 19 с.

10. Брехт Э. А., Коншина В. Н. Применение нейронной сети YOLO для распознавания дефектов // Интеллектуальные технологии на транспорте. 2022. № 2 (30). С. 41–47. DOI: 10.24412/2413-2527-2022-230-41-47.
11. Pan K., Hu H., Gu P. WD-YOLO: A More Accurate YOLO for Defect Detection in Weld X-ray Images // Sensors. 2023. Vol. 23, iss. 21. Art. 8677. 16 p. DOI: 10.3390/s23218677.
12. ГОСТ 33514–2015. Продукция железнодорожного назначения. Правила верификации методик неразрушающего контроля = Railway application. Verification of nondestructive testing techniques. межгосударственный стандарт: введен в действие приказом Федерального агентства по техническому регулированию и метрологии от 29 октября 2015 г. № 1662-ст: дата введения: 2016-08-01. М.: Стандартинформ, 2016. 16 с.

Дата поступления: 01.02.2026

Решение о публикации: 07.02.2026

YOLOv11 for Radiographic Non-Destructive Testing of Welded Joints

Eduard A. Brekht — Postgraduate Student of the Mechanical Handling and Road Building Machines Department. Research interests: neural networks, computer vision, non-destructive testing. E-mail: ed.breht@mail.ru

Vera N. Konshina — PhD in Engineering, Associate Professor of the Mechanical Handling and Road Building Machines Department. Research interests: non-destructive testing methods, statistical analysis, reliability of testing. E-mail: vera.konshina@gmail.com

Emperor Alexander I St. Petersburg State Transport University, 9, Moskovsky ave., Saint Petersburg, 190031, Russia

For citation: Brekht E.A., Konshina V.N. YOLOv11 for Radiographic Non-Destructive Testing of Welded Joints, *Intellectual Technologies on Transport*, 2026, no. 1 (45), pp. 23–32. DOI: 10.20295/2413-2527-2026-145-23-32. (In Russian)

Abstract. *This study presents the application of the YOLOv11 neural network model in radiographic inspection. Purpose: to substantiate the feasibility of employing YOLOv11 for the automatic detection and visualization of defects in radiographic images of welded joints. Methods: the analysis of contemporary tools and techniques, including neural networks, alongside a representative dataset of approximately 100 annotated images, featuring various defect types and image quality indicators, supplemented by augmentation and pre-filtering of the images. Results: it has been demonstrated that the utilization of an enhanced Backbone with C3k2 modules and a C2PSA spatial attention block can enable the model to achieve high values of mAP@0.5–0.95, reliably detecting both large and low-contrast small defects while maintaining acceptable per-image processing times. Practical significance: the results indicate the potential for integrating YOLOv11 into existing non-destructive testing systems for welded joints.*

Keywords: *neural network, radiographic testing, defectograms, detection*

REFERENCES

1. Khanam R., Hussain M. YOLOv11: An Overview of the Key Architectural Enhancements, *ArXiv*, 2024, vol. 2410.17725, 9 p. DOI: 10.48550/arXiv.2410.17725.

2. Ultralytics YOLO11. Available at: <http://docs.ultralytics.com/models/yolo11> (accessed: December 01, 2025).
3. Ultralytics YOLO11. Model Card. Available at: <http://huggingface.co/Ultralytics/YOLO11> (accessed: December 01, 2025).
4. He L.-H., et al. Research on Object Detection and Recognition in Remote Sensing Images Based on YOLOv11, *Scientific Reports*, 2025, vol. 15, art. no. 14032, 25 p. DOI: 10.1038/s41598-025-96314-x.
5. Kretov E. F. Ultrazvukovaya defektoskopiya v energomashinostroyeni [Ultrasonic Flaw Detection in Power Machine Engineering]. Saint Petersburg, SVEN Publishing House, 2014, 312 p. (In Russian)
6. Kotthapalli M., Ravipati D., Bhatia R. YOLOv1 to YOLOv11: A Comprehensive Survey of Real-Time Object Detection Innovations and Challenges, *ArXiv*, 2025, vol. 2508.02067, 13 p. DOI: 10.48550/arXiv.2508.02067.
7. Maity A., Ghosh T. Comparative Analysis of Object Detection Algorithms for Surface Defect Detection, *ArXiv*, 2025, vol. 2510.21811, 14 p. DOI: 10.48550/arXiv.2510.21811.
8. Dymkin G. Ya., Konshina V.N., Nockemann C., Tillack G.-R. Primenenie pokazateley dostovernosti dlya validatsii metodik nerazrushayushchego kontrolya [A Using Confidence Ratings in Validation of Nondestructive Testing Techniques], *Defektoskopiya [Russian Journal of Nondestructive Testing]*, 2000, no. 3, pp. 75–84. (In Russian)
9. GOST 7512–82. Kontrol nerazrushayushchiy. Soedineniya svarnye. Radiograficheskiy metod [GOST 7512–82. Nondestructive testing. Welded joints. Radiography method]. Effective from January 01, 1984. Moscow, StandartInform Publishing House, 2008, 19 p. (In Russian)
10. Breht E.A., Konshina V.N. Primenenie neyronnoy seti YOLO dlya raspoznavaniya defektov [Application of YOLO Neural Network for Defect Recognition], *Intellektualnye tekhnologii na transporte [Intellectual Technologies on Transport]*, 2022, no. 2 (30), pp. 41–47. DOI: 10.24412/2413-2527-2022-230-41-47. (In Russian)
11. Pan K., Hu H., Gu P. WD-YOLO: A More Accurate YOLO for Defect Detection in Weld X-ray Images, *Sensors*, 2023, vol. 23, iss. 21, art. no. 8677, 16 p. DOI: 10.3390/s23218677.
12. GOST 33514–2015. Produktsiya zheleznodorozhnogo naznacheniya. Pravila verifikatsii metodik nerazrushayushchego kontrolya [GOST 33514–2015. Railway application. Verification of nondestructive testing techniques]. Effective from August 01, 2016. Moscow, StandartInform Publishing House, 2008, 16 p. (In Russian)

Received: 01.02.2026

Accepted: 07.02.2026