УДК 620.179.18

СРАВНЕНИЕ ТРАДИЦИОННЫХ И СОВРЕМЕННЫХ МЕТОДОВ ОБНАРУЖЕНИЯ ДЕФЕКТОВ СВАРНЫХ СОЕДИНЕНИЙ ПО ИХ ИЗОБРАЖЕНИЮ

Порываев М.А., студент гр. МРа-241, II курс
Научный руководитель: Чичерин И. В., к.т.н., доцент
Кузбасский государственный технический университет имени Т.Ф. Горбачёва
Россия, г. Кемерово

Контроль качества сварочных работ может выполняться как в процессе сварки путем осуществления контроля амплитудных и скоростных параметров, так и после формирования шва при помощи его визуального контроля, заключающегося в осмотре поверхности изделия невооруженным глазом. Внешним осмотром сварных швов выявляют наружные дефекты: наплывы, трещины, прожоги и т. п. Такая работа считается достаточно трудозатратой и утомительной для оператора, что приводит к ошибкам и характеризуется средним уровнем совпадения в 80 % [1]. Решить проблему автоматизации визуального контроля и повысить достоверность результатов можно за счет использования технологий компьютерного зрения.

Обнаружение объектов на изображениях - ключевая задача компьютерного зрения, решаемая при помощи большого набора методов, которые можно разделить на две группы: традиционные алгоритмы обработки изображений и современные методы глубокого обучения. Рассмотрим их подробнее и проведем их сравнительный анализ.

Традиционные методы распознавания объектов заключаются в выделение признаков с последующей их классификацией. Для чего получаемые изображения подвергаются предварительной обработке для уменьшения шума (например, фильтрация Гаусса) и усиления контрастности. После получения полутонового изображения, необходимо отделить область возможного дефекта от области, не содержащей дефект, для чего применяются различные методы сегментации.

Среди всех способов сегментации наибольшую эффективность показывают следующие методы. Метод моделирования и вычитания фона, в основу которого положено попиксельное сравнение текущего кадра видеопоследовательности с моделью фона [2, 3]. И метод бинаризации, при которой в качестве критерия однородности используется пороговое значение h кода черного цвета [4].

У каждого из приведенных методов есть свои ограничения, так для использования метода моделирования должны выполняться несколько условий [5]. Во-первых, разница между изображениями, рассматриваемыми как фон, должна быть как можно меньше. Во-вторых, должна быть значительная

разница между фоном и передним планом. При выборе второго подхода сегментации возникает проблема нахождения оптимального порога яркости.

После выявления дефектов их необходимо классифицировать. Для наиболее успешного распознавания дефектов используют как геометрические, так и текстурные признаки [6]. Данная работа является трудозатратой и требует поиска компромисса между эффективностью и оперативностью. На завершающем этапе извлечённые признаки дефектов передаются в качестве входных данных классификатору, который формирует шесть основных групп дефектов. В конечном итоге, происходит идентификация конкретного типа дефекта с выделением дефектной области.

Такие классические методы способны обрабатывать изображения на высокой скорости и работать в реальном времени. Они позволяют достигать 75% точности распознавания дефектов, однако остаются весьма чувствительными к изменениям освещения и малоэффективны при работе с большими объемами данных [4].

Переход от традиционных к современным методам распознавания объектов в компьютерном зрении отражает эволюцию технологий. Традиционные методы фокусировались на явном извлечении признаков, тогда как современные подходы, основанные на глубоком обучении, автоматизируют этот процесс, достигая высокой точности и адаптивности. Для автоматического выявления дефектов сварных швов на изображениях предпочтительней всего используются нейронные сети типа CNN (Convolutional Neural Networks) и их модификации, поскольку именно свёрточные сети показывают наилучшие результаты при работе с визуальной информацией.

Для обучения нейронных сетей используется стандартный метод обратного распространения ошибки. Структура сверточных сетей похожа на воронку: от общей картины к деталям. Благодаря свертке нейронная сеть отсеивает лишнюю информацию и оставляет только ту, которая характеризует объект. CNN решают задачи распознавания и классификации по той же модели, как и человеческий мозг.

Вот наиболее распространённые архитектуры нейронных сетей, которые могут быть применены для решения поставленной задачи:

YOLO архитектура - предлагает быстрый и точный метод одновременной локализации и классификации объектов. Изображение рассматривается всего один раз, и одновременно производятся прогнозы относительно всех классов и координат ограничивающих рамок, что делает его очень эффективным для решения задач в реальном времени.

Faster R-CNN архитектура - разделяет задачу на этапы: сначала используется CNN для извлечения признаков изображения. Далее применяется специальная подсеть Region Proposal Network (RPN), которая генерирует возможные области-кандидаты, содержащие объекты. Эти кандидаты передаются второй стадии CNN, где осуществляется классификация объектов и уточнение положения рамок вокруг них [8].

SSD объединяет в себе идеи YOLO и Faster R-CNN, предлагая усредненные показатели производительности и качества, создает единое решение, которое быстро вычисляет и достаточно точно локализирует объекты [9].

Основные характеристики нейронных сетей были сведены в Таблицу 1. Данные архитектуры обладают своими ограничениями, и выбор между ними может быть затруднителен. Одним из оригинальных решений данной проблемы, является создание MSCD (Multistage Component Detection Pipeline) - многоступенчатой системы обнаружения компонентов [10]. Применительно к проблеме поиска дефектов сварки, система может состоять из трех элементов, ответственных за различные задачи обнаружения и классификации. В такой системе первый (большой) детектор обнаруживает сварной шов на общем изображении, после чего он вырезается из входного изображения и выступает в качестве входных данных для последующего (небольшого) детектора компонентов. Второй детектор обнаруживает дефекты сварки, которые обрезаются и передаются в классификатор для их диагностики и регистрации. В такой системе на разные этапы можно использовать наиболее подходящие архитектуры CNN. Подобный подход позволяет увеличить точность системы на 5-30% в зависимости от выбранных классов компонентов.

Таблица 1 – Сравнение нейронных сетей по основным характеристикам

Характеристика	**YOLO**	**Faster R-CNN**	**SSD**
Архитектура	Одноэтапная, простая	Двухэтапная, сложная	Одноэтапная, сбалансированная
Скорость	Высокая (40–155 FPS)	Низкая (7 FPS)	Средняя (22–59 FPS)
Точность	Средняя (63,4% mAP)	Высокая (73,2% mAP)	Высокая (74,3% mAP)
Эффективность	Высокая	Низкая	Высокая
Применение	В режиме реального времени	Критичный уровень точности	Баланс скорости и точности

По итогам изучения и сравнений традиционных методов и методов глубокого обучения была составлена Таблица 2, которая включила в себя все основные критерии, которые необходимо учитывать при выборе подходящей методики поиска дефектов

Таблица 2 – Сравнение традиционных методов с методами глубокого обучения

Критерий	Традиционные	Глубокого обучения
Гибкость	Требуют ручной настройки параметров и признаков. Менее гибкие при изменении условий	Автоматически извлекают признаки из данных, адаптируются к различным задачам без интенсивного ручного вмешательства
Точность	Обычно ниже, особенно в сложных условиях (изменение освещения). Значительно понижается при работе со сложными дефектами	Выше при наличии достаточного объёма данных и правильной архитектуре. Достигает 95% точности и выше в большинстве задач
Масштабируемость	Ограничены в обработке больших объёмов данных и сложных зависимостей	Могут обрабатывать большие объёмы информации, выявляя сложные и тонкие зависимости
Вычислительные ресурсы	Менее требовательны к вычислительным ресурсам	Требуют значительных вычислительных мощностей, особенно при обучении
Обучение	Не требуют аннотированных данных для обучения	Требуют большого количества аннотированных данных для обучения
Область применение	Эффективны в задачах с чётко определёнными объектами и стабильными условиями	Подходят для различных задач: классификация, сегментация, обнаружение объектов. Широкий круг применения

В заключении хотелось бы подытожить результаты проведенного анализа, которые показали, что традиционные методы, хоть и подходят для простых случаев и требуют минимальной вычислительной мощности, однако обладают рядом недостатков, таких как низкая точность, ограниченная сложностью дефектов, и трудоемкость. В свою очередь, CNN очень хорошо проявили себя, в вопросах определения объектов на изображениях. Хоть они и требуют значительных вычислительных ресурсов, их высокая точность и адаптируемость делают их предпочтительными для большинства реальных задач. Они сочетают в себе решения, как задач в режиме реального времени - архитектуры YOLO и SSD, так и задач, требующих максимальной точности и детализации - Faster R-CNN. Использование подхода MSCD способствует еще большему раскрытию потенциала сверточных нейронных сетей, что делает их еще более предпочтительными для решения задачи фиксации дефектов сварного шва.

Список литературы:

1. Wang Y., Sun Y., Lv P., Wang H. Detection of line weld defects based on multiple thresholds and support vector machine // NDT & E International. 2008. V. 41, 517—524.

2. Nixon M, Aguado A. (2020) Feature extraction and image processing for computer vision. 4th ed. Academic Press.

3. Xu Y, Jixiang D, Zhang B, Xu D. Background modeling methods in video analysis: a review and comparative evaluation. CAAI Trans Intell Technol 2016; 1: 43-60.

4. Муравьев С., Погадаева Е. (2020) Автоматизированное распознавание дефектов сварных соединений при визуальном контроле с использованием геометрических признаков.

5. Емельянова М., Смаилова С., Бакланова О. Обнаружение поверхностных дефектов сварных соединений при визуальном контроле методами машинного зрения // КО. 2023. №1.

6. Valavanis I., Kosmopoulos D. Multiclass defect detection and classification in weld radiographic images using geometric and texture features //Expert Systems with Applications. 2010.

7. Погадаева, Е. Распознавание дефектов сварных соединений по фотоизображению для проведения визуального контроля // Молодой ученый. — 2020. — № 43 (333).

8. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks.

9. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. Lecture Notes in Computer Science, 21–37

10. Nguyen, V. N., Jenssen, R., & Roverso, D. (2019). Intelligent Monitoring and Inspection of Power Line Components Powered by UAVs and Deep Learning. IEEE Power and Energy Technology Systems Journal, 6(1), 11–21