



АҚПАРАТТЫҚ ЖҮЙЕЛЕР
ИНФОРМАЦИОННЫЕ СИСТЕМЫ
INFORMATION SYSTEMS

DOI 10.51885/1561-4212_2023_4_177
MPHTI 28.23.15

М.Г. Емельянова¹, С.С. Смаилова²

НАО «Восточно-Казахстанский технический университет имени Д. Серикбаева»,
г. Усть-Каменогорск, Казахстан

¹E-mail: mariya_yemelyanova@mail.ru*

²E-mail: saule_smailova@mail.ru

АВТОМАТИЧЕСКОЕ РАСПОЗНАВАНИЕ ПОВЕРХНОСТНЫХ ДЕФЕКТОВ СВАРКИ ПРИ ПРОИЗВОДСТВЕ ГИБКИХ ТРУБ ИЗ НЕРЖАВЕЮЩЕЙ СТАЛИ

ТОТ БАСПАЙТЫН БОЛАТТАН ЖАСАЛҒАН ИКЕМДІ ҚҰБЫРЛАРДЫ ӨНДІРУДЕ
БЕТКІ ДӘНЕКЕРЛЕУ АҚАУЛАРЫН АВТОМАТТЫ ТҮРДЕ ТАНУ

AUTOMATIC RECOGNITION OF SURFACE WELD DEFECTS IN THE PRODUCTION
OF FLEXIBLE STAINLESS STEEL PIPES

Аннотация. В статье описан процесс автоматического распознавания поверхностных дефектов сварки на кадрах видеопотока при изготовлении гибких труб из нержавеющей стали. Исследуются дефекты, которые появляются при автоматической дуговой сварке вольфрамовым электродом в среде инертного газа. Для обнаружения и локализации различных дефектов сварки на кадрах видеопотока представлен универсальный алгоритм на основе метода вычитания фона. Предложено решение задачи распознавания таких дефектов как несплавление и окисление металла. Сформирован набор данных, содержащий текстурные признаки дефектов. Обучены классификаторы с использованием метода опорных векторов. Экспериментальные исследования показали, что предлагаемые решения позволяют оперативно обнаруживать любые отклонения, возникающие при сваривании металла, и распознавать определённые дефекты сварки на обрабатываемых кадрах видеопотока.

Ключевые слова: дефекты сварки, автоматическое обнаружение дефектов, классификация дефектов, извлечение признаков, SVM.

Аңдатпа. Мақалада тот баспайтын болаттан жасалған икемді құбырларды жасау кезінде бейне ағынының жақтауларындағы дәнекерлеудің беткі ақауларын автоматты түрде тану процесі сипатталған. Инертті газ ортасында вольфрам электродымен автоматты доғалық дәнекерлеу кезінде пайда болатын ақаулар зерттеледі. Бейне ағынының кадрларында дәнекерлеудің әртүрлі ақауларын анықтау және оқшаулау үшін фонды азайту әдісіне негізделген эмбебап алгоритм ұсынылған. Сондай-ақ, металдың балқымауы және тотығуы сияқты ақауларды тану мәселесін шешу ұсынылады. Ақаулардың текстуралық белгілері бар мәліметтер жиынтығы құрылды. Тірек векторлық машинаны қолданып классификаторлар (жіктеушілер) оқытылды. Эксперименттік зерттеулер көрсеткендей, ұсынылған шешімдер металды дәнекерлеу кезінде пайда болатын кез-келген ауытқуларды тез анықтауға және өңделген бейне ағынының кадрларында дәнекерлеудің белгілі бір ақауларын тануға мүмкіндік береді.

Түйін сөздер: дәнекерлеу ақаулары, ақауларды автоматты түрде анықтау, ақауларды жіктеу, белгілерді шығару, SVM.

Abstract. The paper describes the automatic recognition of surface welding defects on video stream

frames while manufacturing flexible stainless steel pipes. The defects that appear during automatic tungsten inert gas welding are studied. A universal algorithm based on the background subtraction method is presented for detecting and localizing various welding defects on video stream frames. A solution to the problem of recognizing such defects as lack of fusion and scaled surface is also proposed. A dataset containing texture features of defects was created. Classifiers were trained using the support vector machine. Experimental studies have shown that the proposed solutions allow for prompt detection of any deviations occurring during metal welding and recognize certain welding defects on the processed frames of the video stream.

Keywords: *weld defects, weld defect detection, classification, feature extraction, SVM.*

Введение. Современные технические средства и технологии, а также методы компьютерного зрения и машинного обучения дают возможность решать задачи автоматического распознавания изображений. Процесс распознавания изображения заключается в получении выходной информации о принадлежности исследуемого изображения или его фрагмента к определённому классу с помощью различных методов преобразования входных данных. Задачи распознавания изображений возникают в различных областях, в частности, в промышленности для обнаружения и классификации дефектов сварки.

В системах отопления и водоснабжения используются гибкие гофрированные сварные трубы из нержавеющей стали, обладающие высокими техническими и эксплуатационными характеристиками, просты в монтаже. Гибкие трубы из нержавеющей стали изготавливаются на автоматизированной производственной линии. Одним из этапов изготовления труб является сварка стыка цилиндрической заготовки из стальной ленты, которая формируется на линии. Для сварки стыка используется автоматическая дуговая сварка вольфрамовым электродом в инертном газе – TIG (Tungsten Inert Gas), происходящая непрерывно до момента остановки производственной линии. В процессе сварки возможно появление дефектов [1]. Дефекты сварки – это определённые отклонения от технических требований, которые могут привести к негативным последствиям, к невозможности дальнейшей эксплуатации. Появление дефектов связано с несоответствующими нормам металлом, сварочными материалами, технологическими нарушениями. Дефекты сварки могут быть как внутри, так и снаружи. Для гибких труб из нержавеющей стали характерны поверхностные дефекты, так как свариваемый металл очень тонкий. Чаще всего при TIG сварке возникают такие дефекты как несплавление металла, прожог, окисление. Несплавление – это отсутствие сварки между краями металла. Прожог представляет собой сквозное отверстие с закруглёнными очертаниями. Дефект окисление при сварке нержавеющей стали появляется в виде радужных разводов различной насыщенности. Визуально дефекты имеют значительные отличия от качественного сварного соединения.

Одним из методов оценки качества сварки является визуальный контроль. Процедура выполняется оператором и позволяет обнаружить поверхностные дефекты. При изготовлении гибких труб из нержавеющей стали требуется непрерывный контроль, так как дефекты могут появиться в любой момент времени. На эффективность визуального контроля оказывает влияние физическое состояние и опыт работы оператора [2-5]. Использование машинного зрения позволит исключить субъективное влияние на результат [2-5].

Актуальной является задача автоматического обнаружения и распознавания дефектов TIG сварки в видеопотоке, содержащим кадры со сварным соединением стыка кромок металла, получаемым с камеры после этапа сваривания.

Основой для автоматического распознавания дефектов сварки может являться классическая информационная технология, состоящая, как правило, из следующих этапов: получение изображения, предварительная обработка изображения, сегментация и локализация или обнаружение дефектов, классификация (рис. 1) [5-8].




Рисунок 1. Основные этапы автоматического распознавания дефектов сварки

В обзорных статьях [6, 7] представлены поэтапно результаты исследований учёных в области распознавания дефектов сварки по радиографическим изображениям. В работах [2, 5] показаны решения задачи автоматического обнаружения дефектов сварки на фотоизображениях. Sun J. и соавторы в [9] предложили решение задачи обнаружения и классификации дефектов сварки в реальном времени на основе методов машинного зрения. Широко применяются методы машинного обучения для решения задачи распознавания дефектов [4, 6-8, 10-15]. Часто используемыми являются классификаторы, обученные на извлекаемых признаках дефектов [6]. Для классификации дефектов исследователи обычно выбирают геометрические и текстурные признаки [6, 16]. Набор признаков и метод построения классификатора являются ключевыми факторами, влияющими на эффективность распознавания [6]. В случае определения большого числа признаков дефектов требуется их отбор для сокращения вычислительной нагрузки. В качестве метода построения классификатора широко используют нейронные сети (Artificial Neural Network, ANN) [6]. Авторы [8, 13-15] указывают на достаточно высокую точность классификаторов дефектов сварки, построенных на основе метода опорных векторов (Support Vector Machine, SVM). В обзоре [4] представлены различные исследования технологий глубокого обучения, используемые в области распознавания поверхностных дефектов на различных изделиях промышленного производства, в том числе и дефектов сварки. Одним из преимуществ глубокого обучения является то, что для построения моделей не требуется извлечение и отбор признаков. Для машинного обучения, в частности, глубокого обучения, необходимы большие объёмы входных данных [16], значительные вычислительные и временные ресурсы.

Целью статьи является решение задачи автоматического обнаружения и распознавания поверхностных дефектов TIG сварки в процессе непрерывного изготовления гибких труб из нержавеющей стали в соответствии с классической информационной технологией с учётом ограниченного количества данных.

Методы исследования и алгоритмы. Цифровые изображения (кадры) получают с помощью камеры [8, 9] и автоматически непрерывно обрабатывают. После получения кадра выполняется его предварительная обработка: преобразование изображения RGB в полутоновое изображение; обрезка неинформативной области; уменьшение шума, улучшение контрастности в зависимости от качества съёмки [6]. Предварительная обработка необходима для улучшения качества изображения и в дальнейшем позволит получить более точный результат сегментации, а также сократить количество ложных обнаружений дефектов.

После предварительной обработки возникает задача автоматического обнаружения дефекта: необходимо выявить отсутствие или наличие дефекта сварки на изображении и выполнить локализацию дефекта при его обнаружении. Для решения этой задачи выполняется сегментация – выделение области возможного дефекта на изображении [2, 6]. В исследованиях [9] используется метод вычитания фона, который позволяет обнаружить изменения в последовательностях изображений, что необходимо для непрерывной обработки кадров. Сущность метода состоит в вычитании кадров видеопотока из эталонной модели изображения [17]. Эталонные модели могут быть построены на основе различных методов [9, 17]. Для описываемой предметной области эталонной моделью

является изображение информативной области с металлом трубы и сварным соединением, не содержащим какие-либо дефекты, полученное путём усреднения заданного количества кадров [18].

Для решения задачи обнаружения дефектов сварки на кадрах видеопотока предлагается универсальный алгоритм, позволяющий обнаружить различные типы дефектов сварки на кадрах видеопотока [18]. Краткое словесное описание алгоритма обработки кадров видеопотока [18]:

1. Построение эталонной модели фона.
2. Предварительная обработка поступающего кадра.
3. Вычитание модели фона из обработанного кадра.
4. Построение бинарной маски в результате пороговой обработки полученного разностного изображения.
5. Подсчёт белых пикселей в бинарном изображении.
6. Сравнение подсчитанного количества белых пикселей с заданным значением, полученным экспериментальным путём.
7. При выполнении условия сравнения указывается на наличие дефекта и происходит обозначение ограничивающей рамкой области, содержащей дефект на обрабатываемом кадре.
8. Обновление эталонной модели фона через определённый промежуток времени.

В случае обнаружения дефекта сварки на кадре видеопотока требуется уточнение его типа, то есть необходимо решение задачи классификации. На рис. 2 приведена схема классификации дефекта на изображении. Автоматически из локализованной области дефекта на изображении извлекаются признаки, и уже обученный классификатор относит дефект к определённому классу.



Рисунок 2. Схема классификации дефекта на изображении

Для обучения классификатора требуется набор данных, сформированный из признаков. Различные поверхностные дефекты сварки имеют текстурный характер, следовательно, возможно выявление структуры исследуемого изображения дефекта. В данном исследовании используются текстурные признаки, предложенные Р. Хараликом [19]. Статистические текстурные признаки второго порядка получают из матрицы смежности уровней серого (Gray Level Co-occurrence Matrix, GLCM) [15, 16, 19]. Элементы GLCM представляют собой частоты встречаемости пар значений яркости изображения по заданному направлению [15]. Матрица смежности обозначается как $P(i, j, d, \varphi)$, где i и j – яркости соседних точек на изображении, расположенных на расстоянии d друг от друга, при угловом направлении φ [19]. Размер GLCM определяется количеством градаций яркости изображения. Нормализованная матрица смежности $p(i, j)$ получается путём деления каждого элемента матрицы на сумму всех элементов матрицы.

Для создания набора данных из областей изображений, содержащих дефекты сварки,

извлекались 12 текстурных признаков: энергия (второй угловой момент) (1), контраст (2), корреляция (3), дисперсия (4), обратный разностный момент (5), суммарное среднее, суммарная дисперсия, суммарная энтропия, энтропия, разностная дисперсия, разностная энтропия, первая информационная мера корреляции [15, 19]. В данном исследовании признаки вычисляются на основе матрицы смежности с параметрами $d = 1$ и $\varphi = 0^\circ$.

$$f_1 = \sum_i \sum_j p(i, j)^2 \quad (1)$$

$$f_2 = \sum_i \sum_j (i - j)^2 p(i, j) \quad (2)$$

$$f_3 = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}, \quad (3)$$

где $\mu_x, \mu_y, \sigma_x, \sigma_y$ – средние значения и среднеквадратические отклонения p_x и p_y .

$$f_4 = \sum_i \sum_j (i - \mu)^2 p(i, j), \quad (4)$$

где μ – среднее значение матрицы смежности.

$$f_5 = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j). \quad (5)$$

Из значений текстурных признаков формируется вектор признаков, который описывает дефект. Значение каждого текстурного признака является вещественным числом и не привязано ни к каким единицам измерения. Признак энергия или второй угловой момент отражает однородность и грубость текстуры. Значение признака располагается в интервале от 0 до 1. Высокое значение энергии указывает на однородность. Признак контраст или инерция отражает резкость изображения и глубину «борозд». Низкое значение признака соответствует размытой текстуре. Корреляция отражает постоянство текстуры изображения. Обратный разностный момент характеризует «сглаженность» и однородность изображения. Значение энтропии связано со случайностью и неравномерностью. Другие указанные статистические оценки соответствуют понятиям математической статистики.

Для обучения классификатора предлагается использовать один из популярных алгоритмов машинного обучения – метод опорных векторов [16, 20]. Достоинство этого метода в том, что для обучения классификатора достаточно небольшого набора данных [16]. На рис. 3 представлена схема построения классификатора.




Рисунок 3. Схема построения классификатора

Метод опорных векторов – это метод обучения с учителем, для которого требуется набор размеченных данных. Данные делятся на обучающие и тестовые. На основе обучающей выборки строится модель. Тестовые данные позволяют оценить качество классификации. Метод опорных векторов основывается на построении оптимальной гиперплоскости, которая разделяет данные на классы.

Полученные результаты. Выполнена программная реализация описанного алгоритма обнаружения и локализации дефектов сварки на кадрах видеопотока и подтверждена его работоспособность, сформирован набор данных, состоящий из значений текстурных признаков изображении определённых дефектов сварки, обучены классификаторы, определено качество полученных моделей. Для решения задачи распознавания были использованы следующие программные средства: интегрированная среда разработки Visual Studio 2019 (язык программирования C#), библиотека EmguCV, платформа Accord.NET.

Предлагаемый алгоритм протестирован на реальных данных: более 40000 кадрах, содержащих сварные соединения без дефектов и такие дефекты как несплавление и окисление металла [18]. В результате предварительной обработки кадры преобразовывались в полутоновые, выделялась информативная область 1010×135 пикселей [18]. Порог для построения бинарной маски был принят как 50 на основании экспериментов. Сравнение количества белых пикселей осуществлялось с 7×103 [18]. Это значение также было определено экспериментальным путём. На рис. 4 приведены примеры работы алгоритма обнаружения и локализации дефектов сварки в видеопотоке.




Рисунок 4. Примеры локализации дефектов сварки на кадрах видеопотока: окисление металла (а), (б); несплавление металла (в), (г)

Точность (precision) обнаружения дефектов сварки на основе предложенного алгоритма составила 91,9 %, полнота (recall) – 93 % [18].

Для формирования набора данных было выбрано 545 областей изображений, содержащих дефекты сварки, полученных в результате работы алгоритма, и 32 изображения, полученных «вручную». На 265 областях изображений был виден такой дефект, как несплавление металла, на 312 – окисление. Числовые значения 12 текстурных признаков, извлечённых из каждой интересующей области, экспортированы в файл csv. Сформированный набор данных разделён на обучающую и тестовую выборку случайным образом.

В обучающей выборке содержалось 70 % всех векторов признаков, в тестовой – 30 %.

Важными являются исследования, связанные с размерностью вектора признаков. Снижение размерности позволит сократить время обработки данных, время обучения и тестирования. Кроме этого, удаление незначительных признаков может привести к увеличению точности распознавания.

Значения извлечённых текстурных признаков были проанализированы. Установлено, что между значениями некоторых текстурных признаков областей изображений несплавления металла и значениями текстурных признаков областей изображений окисления металла имеются значительные отличия. Проводилось обучение и проверка качества классификаторов при разном количестве признаков в наборе данных. Классификаторы строились для определения двух классов дефектов сварки: несплавления и окисления металла. При создании классификаторов на основе метода опорных векторов для сравнения были использованы линейное ядро (Linear), ядрорадиальной базисной функции (Rbf), ядро хи-квадрат (Chi2) с одинаковыми параметрами $C = 100$, $\gamma = 0,005$.

Качество обученных классификаторов определялось метрикой Accuracy, описывающей общую точность по всем классам. Оценка качества моделей осуществлялась на базе тестовых выборок. Сначала были построены классификаторы на обучающей выборке, содержащей по 12 признаков, извлечённых из областей дефектов, при этом Accuracy линейного классификатора составила 94 %, Accuracy для классификаторов на опорных векторах с ядрами Rbf и Chi2 – 67 % и 92 % соответственно. Затем строились классификаторы на обучающих выборках, в которых количество признаков уменьшалось. Было выявлено, что лучшие результаты показали классификаторы, для обучения которых использовались векторы из двух признаков (контраст и дисперсия). В таком случае метрика Accuracy построенных моделей определена при ядрах: Linear – 98 %, Chi2 – 99 %, Rdf – 94 %. В данном исследовании сокращение размерности вектора признаков за счёт удаления неинформативных признаков позволило увеличить точность классификации. При расширении набора данных за счёт добавления векторов признаков, относящихся к другим классам дефектов, потребуются анализ признаков и обучение классификаторов.

Заключение. В работе предложено решение задачи автоматического распознавания поверхностных дефектов сварки при производстве гибких труб из нержавеющей стали в соответствии с классической технологией: получение изображения, предварительная обработка, обнаружение дефектов, классификация дефектов.

Исследования проводились на реальных кадрах видеопотоков, полученных с камеры. Для обнаружения дефектов сварки без участия человека предложен универсальный алгоритм, основанный на методе моделирования и вычитания фона, позволяющий «увидеть» различные дефекты в процессе непрерывного сваривания металла на производственной линии. Алгоритм позволяет обнаруживать дефекты с достаточной точностью, следовательно, возможно его применение на практике.

Сформирован набор данных, содержащий извлечённые текстурные признаки из областей изображений дефектов. Построены классификаторы на основе линейного метода и нелинейных методов опорных векторов. Лучшие результаты показал классификатор с ядром хи-квадрат. Классификатор может определить только два класса дефектов: несплавление и окисление металла из-за недостаточного количества полученных реальных изображений возможных дефектов сварки.

В дальнейшем планируется проведение исследований для распознавания других типов дефектов сварки в видеопотоке, построение классификаторов и оценка их качества на расширенном наборе данных.

Список литературы

1. ГОСТ Р ИСО 6520-1-2012. Сварка и родственные процессы. Классификация дефектов геометрии и сплошности в металлических материалах. Часть 1. Сварка плавлением; введ. 2014-01-01. – М.: Стандартиформ, 2014.
2. Нгуен Д.К., Муравьев С.В. Сегментация изображений методом наращивания областей при автоматическом обнаружении дефектов сварки // Электронные средства и системы управления. Материалы докладов Международной научно-практической конференции. – 2021. – № 1-2. – С. 106-109.
3. Li Y., Hu M., Wang T. Visual inspection of weld surface quality // *Journal of Intelligent & Fuzzy Systems*. – 2020. – Vol. 39, pp. 1-10. DOI: 10.3233/JIFS-179993.
4. Prunella M., Scardigno R., Buongiorno D., Brunetti A., Longo N., Carli R., Dotoli M., Bevilacqua V. Deep learning for automatic vision-based recognition of industrial surface defects: a survey // *IEEE Access*. – 2023. DOI: 10.1109/ACCESS.2023.3271748.
5. Muravyov S.V., Pogadaeva E.Yu. Recognition ability of interval fusion with preference aggregation in weld defects images analysis // 17th IMEKO TC10 Conference «Global Trends in Testing, Diagnostics & Inspection for 2030». – 2020, pp. 271-276.
6. Hou W., Zhang D., Wei Y., Guo J., Zhang X. Review on computer aided weld defect detection from radiography images // *Applied Sciences*. – 2020. – Vol. 10, No. 5, pp. 1878. DOI: 10.3390/app10051878.
7. Purnomo T. W., Danitasari F., Handoko D. Weld defect detection and classification based on deep learning method: A Review // *Jurnal Ilmu Komputer Dan Informatika (Journal of Computer Science and Information)*. – 2023. – Vol. 16, pp. 77-87. DOI: 10.21609/jiki.v16i1.1147.
8. Praveen Kumar R., Deivanathan R., Jegadeeshwaran R. Welding defect identification with machine vision system using machine learning // *Journal of Physics: Conference Series*. – 2020. – Vol. 1716. DOI: 10.1088/1742-6596/1716/1/012023.
9. Sun J., Li C., Wu X.J., Palade V., Fang W. An effective method of weld defect detection and classification based on machine vision // *IEEE Transactions on Industrial Informatics*. – 2019. – Vol. 15, pp. 6322-6333. DOI: 10.1109/TII.2019.2896357.
10. Yang D., Cui Y., Yu Z., Yuan H. Deep learning based steel pipe weld defect detection // *Applied artificial intelligence*. – 2021. – Vol. 35, No. 15, pp. 1237-1219. DOI: 10.1080/08839514.2021.1975391.
11. Zhu M., Ge W., Liu Z. Deep learning-based classification of weld surface defects // *Applied Sciences*. – 2019. – Vol. 9, pp. 3312. DOI: 10.3390/app9163312.
12. Hou W., Wei Y., Jie G., Jin, Y., Zhu C. Automatic detection of welding defects using deep neural network // *Journal of Physics: Conference Series*. – 2018. – Vol. 933. DOI: 10.1088/1742-6596/933/1/012006.
13. Kalaiselvi V., Aravindhar D. J. An efficient weld image classification system using wavelet and support vector machine // 2019 3rd International conference on computing and communications technologies (ICCCT) – 2019, pp. 46-49. DOI: 10.1109/ICCCT2.2019.8824884.
14. Malarvel M., Singh H. An autonomous technique for weld defects detection and classification using multi-class support vector machine in X-radiography image // *Optik*. – 2020. – Vol. 231. DOI: 10.1016/j.ijleo.2021.166342.
15. Jiang H., Zhao Y., Gao J., Zhao W. Weld defect classification based on texture features and principal component analysis // *Insight - Non-Destructive testing and condition monitoring*. – 2016. – Vol. 58, No. 4, pp.194-200. DOI:10.1784/insi.2016.58.4.194.
16. Hou W., Rao L., Zhu A., Zhang D. Feature fusion for weld defect classification with small dataset // *Journal of Sensors*. – 2022. – Vol. 2022, pp. 1-9. DOI: 10.1155/2022/8088202.
17. Мареєв А. В. Методы локализации объектов в видеопотоке // *Радиотехнические и телекоммуникационные системы*. – 2021. – № 3.
18. Емельянова М.Г., Смаилова С.С., Бакланова О.Е. Обнаружение поверхностных дефектов сварных соединений при визуальном контроле методами машинного зрения // *Компьютерная оптика*. – 2023. – Т. 47, № 1. – С. 112-117. DOI: 10.18287/2412-6179-CO-1137.

Дополнительный список литературы

19. Haralick R.M., Shanmugan K., Dinstein I. Textural features for image classification // *IEEE Transactions on systems, man and cybernetics*. – 1973. – Vol. SMC-3, No. 6, pp. 610-621. DOI: 10.1109/TSMC.1973.4309314.
20. Cortes C., Vapnik V. Support-vector networks // *Machine Learning*. – 1995. – Vol. 20, pp. 273-297. DOI: 10.1007/BF00994018.

References

1. GOST R ISO 6520-1-2012. Svarka i rodstvennyye processy. Klassifikaciya defektov geometrii i sploshnosti v metallicheskih materialah. CHast' 1. Svarka plavleniem; 2014-01-01. – M.: Standartinform, 2014.
2. Nguen D.K., Murav'ev S.V. Segmentaciya izobrazhenij metodom narashchivaniya oblastej pri avtomaticheskom obnaruzhenii defektov svarki // Elektronnyye sredstva i sistemy upravleniya. Materialy dokladov Mezhdunarodnoj nauchno-prakticheskoj konferencii. – 2021. – № 1-2. – S. 106-109.
3. Li Y., Hu M., Wang T. Visual inspection of weld surface quality // Journal of Intelligent & Fuzzy Systems. – 2020. – Vol. 39, pp. 1-10. DOI: 10.3233/JIFS-179993.
4. Prunella M., Scardigno R., Buongiorno D., Brunetti A., Longo N., Carli R., Dotoli M., Bevilacqua V. Deep Learning for Automatic Vision-Based Recognition of Industrial Surface Defects: A Survey // IEEE Access. – 2023. DOI: 10.1109/ACCESS.2023.3271748.
5. Muravyov S.V., Pogadaeva E.Yu. Recognition Ability of Interval Fusion with Preference Aggregation in Weld Defects Images Analysis // 17th IMEKO TC10 Conference «Global Trends in Testing, Diagnostics & Inspection for 2030». – 2020, pp. 271-276.
6. Hou W., Zhang D., Wei Y., Guo J., Zhang X. Review on Computer Aided Weld Defect Detection from Radiography Images // *Applied Sciences*. – 2020. – Vol. 10, No. 5, pp. 1878. DOI: 10.3390/app10051878.
7. Purnomo T. W., Danitasari F., Handoko D. Weld Defect Detection and Classification Based on Deep Learning Method: A Review // Jurnal Ilmu Komputer Dan Informasi (Journal of Computer Science and Information). – 2023. – Vol. 16, pp. 77-87. DOI: 10.21609/jiki.v16i1.1147.
8. Praveen Kumar R., Deivanathan R., Jegadeeshwaran R. Welding Defect Identification with Machine Vision System Using Machine Learning // Journal of Physics: Conference Series. – 2020. – Vol. 1716. DOI: 10.1088/1742-6596/1716/1/012023.
9. Sun J., Li C., Wu X.J., Palade V., Fang W. An Effective Method of Weld Defect Detection and Classification Based on Machine Vision // IEEE Transactions on Industrial Informatics. – 2019. – Vol. 15, pp. 6322-6333. DOI: 10.1109/TII.2019.2896357.
10. Yang D., Cui Y., Yu Z., Yuan H. Deep Learning Based Steel Pipe Weld Defect Detection // Applied Artificial Intelligence. – 2021. – Vol. 35, No. 15, pp. 1237-1219. DOI: 10.1080/08839514.2021.1975391.
11. Zhu M., Ge W., Liu Z. Deep Learning-Based Classification of Weld Surface Defects // *Applied Sciences*. – 2019. – Vol. 9, pp. 3312. DOI: 10.3390/app9163312.
12. Hou W., Wei Y., Jie G., Jin, Y., Zhu C. Automatic Detection of Welding Defects Using Deep Neural Network // Journal of Physics: Conference Series. – 2018. – Vol. 933. DOI: 10.1088/1742-6596/933/1/012006.
13. Kalaiselvi V., Aravindhar D. J. An Efficient Weld Image Classification System Using Wavelet and Support Vector Machine // 2019 3rd International Conference on Computing and Communications Technologies (ICCT) – 2019, pp. 46-49. DOI: 10.1109/ICCT2.2019.8824884.
14. Malarvel M., Singh H. An Autonomous Technique for Weld Defects Detection and Classification Using Multi-Class Support Vector Machine In X-Radiography Image // *Optik*. – 2020. – Vol. 231. DOI: 10.1016/j.ijleo.2021.166342.
15. Jiang H., Zhao Y., Gao J., Zhao W. Weld Defect Classification Based on Texture Features and Principal Component Analysis // *Insight - Non-destructive Testing and Condition Monitoring*. – 2016. – Vol. 58, No. 4, pp. 194-200. DOI: 10.1784/insi.2016.58.4.194.
16. Hou W., Rao L., Zhu A., Zhang D. Feature Fusion for Weld Defect Classification with Small Dataset // *Journal of Sensors*. – 2022. – Vol. 2022, pp. 1-9. DOI: 10.1155/2022/8088202.
17. Mareev A. V. Metody lokalizacii ob"ektov v videopotoke // *Radiotekhnicheskie i telekommunikacionnye sistemy*. – 2021. – № 3.
18. Yemelyanova M.G., Smailova S.S., Baklanova O.E. Detection of Surface Defects in Welded Joints During Visual Inspections Using Machine Vision Methods // *Computer Optics*. – 2023. – Vol. 47, No. 1, pp. 112-117. DOI: 10.18287/2412-6179-CO-1137.

Additional references

19. Haralick R.M., Shanmugan K., Dinstein I. Textural Features for Image Classification // *IEEE Transactions on Systems, Man and Cybernetics*. – 1973. – Vol. SMC-3, No. 6, pp. 610-621. DOI: 10.1109/TSMC.1973.4309314.
20. Cortes C., Vapnik V. Support-Vector Networks // *Machine Learning*. – 1995. – Vol. 20, pp. 273-297. DOI: 10.1007/BF00994018.