

АВТОМАТИЧЕСКАЯ СЕГМЕНТАЦИЯ МЕТОДОМ КОМПЛЕКСИРОВАНИЯ ИНТЕРВАЛОВ АГРЕГИРОВАНИЕМ ПРЕДПОЧТЕНИЙ ПРИ РАСПОЗНАВАНИИ ДЕФЕКТОВ СВАРКИ

© 2023 г. С.В. Муравьев^{1,*}, Д.К. Нгуен^{1,**}

¹Томский политехнический университет, Россия 634050 Томск, пр-кт Ленина, 30
E-mail: *muravyov@tpu.ru; **nguyen@tpu.ru

Поступила в редакцию 07.09.2023; после доработки 22.09.2023
Принята к публикации 22.09.2023

Проверка качества сварного шва обычно выполняется в ходе визуального контроля и значительно зависит от опыта оператора. В статье предложен подход к автоматическому обнаружению и классификации дефектной области, где сегментация анализируемого фотоизображения сварного шва (т.е. его разбиение на дефектную и бездефектную области) осуществляется с помощью процедуры наращивания областей. Начальные точки для этой процедуры выбираются предложенным авторами робастным методом комплексирования интервалов агрегированием предпочтений (IF&PA) на основе анализа гистограммы изображения. Проверка предложенного подхода на реальных фотоизображениях показала его способность обнаруживать разные типы дефектов сварного шва с более высокой точностью по сравнению с традиционными методами, такими как метод Оцу и метод k -средних.

Ключевые слова: обработка изображения, сегментация, гистограмма, уровень серого, дефектная область, сварной шов, комплексирование интервалов, агрегирование предпочтений.

AUTOMATIC SEGMENTATION BY THE METHOD OF INTERVAL FUSION WITH PREFERENCE AGGREGATION WHEN RECOGNIZING WELD DEFECTS

S.V. Muravyov^{1,*}, D.C. Nguyen^{1,**}

¹Tomsk Polytechnic University, Lenin Ave., 30, Tomsk, 634050 Russia
E-mail: *muravyov@tpu.ru; **nguyen@tpu.ru

Quality control of welding is usually carried out during the visual inspection process and is highly dependent on an operator experience. In the paper, it is proposed an approach to automatic detection and classification of a defective region, where segmentation of the analyzed photographic image of a weld (i.e., its division into defective and defect-free regions) is performed using the region growing procedure. The starting points for this procedure are selected by the authors' robust method of interval fusion with preference aggregation (IF&PA) on the base of image histogram analysis. Testing of the proposed approach for real life photographic images showed its ability to detect different types of weld defects with higher accuracy compared to traditional methods such as Otsu method and k -means.

Keywords: image processing, segmentation, histogram, defect region, welding joint, interval fusion, preference aggregation.

DOI: 10.31857/S0130308223120047, EDN: XIFFYI

ВВЕДЕНИЕ

При автоматизации визуального контроля качества сварных швов [1—6] процесс распознавания дефектов может включать в себя несколько этапов (рис. 1). Входное изображение предварительно обрабатывается с целью уменьшения шумов. Затем выполняется основная операция обработки изображения — *сегментация* — для того, чтобы получить выходное изображение, разделенное на однородные области (дефектную и бездефектную) с известными границами. Каждая однородная область должна соответствовать реальному объекту на изображении. Процесс завершается отнесением дефектной области к одному из известных *классов* в соответствии со стандартом ГОСТ Р ИСО 6520 [7].



Рис. 1. Процесс распознавания дефектов сварного шва.

Один из популярных методов сегментации, который будет использован в данной работе, — наращивание областей (region growing, НО) [8, 9] — включает каждый пиксель входного изображения в дефектную или бездефектную область, для чего выбираются *начальные точки-пиксели* (seeds) и к ним последовательно присоединяются соседние пиксели с ближайшим значением яркости тона.

От правильности выбора значения начальной точки зависит качество результата сегментации и итоговая точность всего процесса распознавания. При этом возможны два режима работы реализующего распознавание программного обеспечения (ПО):

1) интерактивный, когда осуществляющий визуальный контроль оператор отмечает (например, с помощью «мыши») на изображении определенные пиксели, значения яркости которых наилучшим, по его мнению, образом характеризуют ту или иную область;

2) автоматический, когда выбор подходящих пикселей осуществляется программным обеспечением без участия оператора.

В предыдущей публикации [2] авторами был предложен алгоритм автоматизированного распознавания дефектов сварных соединений (АРД). Целью данной статьи является обсуждение результатов исследований по дальнейшему развитию АРД, которые обеспечивают возможность реализации автоматической сегментации анализируемых изображений.

Интерактивный режим будет использоваться в ходе экспериментальных исследований предложенного алгоритма автоматического распознавания дефектов как способ получения заведомо правильных результатов распознавания.

КОМПЛЕКСИРОВАНИЕ ИНТЕРВАЛОВ АГРЕГИРОВАНИЕМ ПРЕДПОЧТЕНИЙ

Автоматический выбор начальных точек для метода НО предлагается осуществлять предложенным и развиваемым авторами методом комплексования интервалов агрегированием предпочтений (interval fusion with preference aggregation — IF&PA), см. статьи [10, 11]. Метод IF&PA позволяет находить для заданной выборки неравнозначных (т.е. имеющих разную дисперсию) значений $\{x_1, x_2, \dots, x_m\}$ некоторой физической величины X оценку x^* центра ее распределения. Эта оценка, которую будем называть *результатом комплексования* x^* , характеризуется повышенными робастностью, точностью и достоверностью по сравнению с традиционными оценками, такими как среднее арифметическое, среднее взвешенное, выборочная медиана и др. [11]. Сформулируем кратко суть метода IF&PA.

Пусть имеется набор m замкнутых интервалов $\{I_k\}, k = 1, \dots, m$, на вещественной числовой оси, где каждый интервал характеризуется средней точкой x_k , нижней границей $x_k - \varepsilon_k$ и верхней границей $x_k + \varepsilon_k$, так что $I_k = [x_k - \varepsilon_k, x_k + \varepsilon_k]$; $x_k, \varepsilon_k \in \mathbf{R}$. Ключевая идея метода IF&PA состоит в преобразовании каждого из m исходных интервалов $\{I_k\}, k = 1, \dots, m$, в ранжирование принадлежащих этому интервалу n дискретных значений из множества $A = \{a_1, a_2, \dots, a_n\} \in \mathbf{R}$.

Ранжированием называется бинарное отношение предпочтения λ на множестве A в виде цепочки $\lambda = a_2 \succ a_1 \succ \dots \succ a_s \sim a_t \succ \dots \succ a_p \sim a_q$, где символы \succ и \sim обозначают бинарные отношения строгого порядка и толерантности соответственно. Заметим, что порядок предпочтения в ранжировании всегда ориентирован слева направо, т.е. более предпочтительные альтернативы находятся слева. Благодаря этому, для удобства и краткости обозначений, будем использовать очевидное компактное представление для ранжирования: $2, 1, \dots (s, t) \dots (p, q)$, в котором элементы обозначены их индексами, подмножества индексов толерантных элементов (классов эквивалентности) заключены в круглые скобки, а символы \succ и \sim опущены. Например, ранжирование $a_2 \succ a_5 \sim a_1 \succ a_3 \sim a_4 \succ a_6$ в краткой форме выглядит как $2(5,1)(3,4)6$.

Сформируем диапазон актуальных значений (ДАЗ) $A = \{a_1 < a_2 < \dots < a_n\}$ из принадлежащих интервалам строго упорядоченных дискретных значений $a_i, i = 1, \dots, n$, где $a_1 = \min \{x_k - \varepsilon_k | k = 1, \dots, m\}$ и $a_n = \max \{x_k + \varepsilon_k | k = 1, \dots, m\}$, а элемент $a_i = a_{i-1} + h, i = 2, \dots, n$, где норма $h = (a_n - a_1)/(n - 1)$ — это расстояние между любыми двумя соседними дискретными значениями.

Множество A строго упорядоченных дискретных значений $a_i, i = 1, \dots, n$, используется для формирования профиля предпочтений $\Lambda = \{\lambda_1, \lambda_2, \dots, \lambda_m\}$, состоящего из ранжирований, представляющих интервалы I_k . Обозначим через A_k множество всех элементов из A , принадлежащих интервалу I_k , т.е. $A_k = \{a_i | a_i \in I_k \wedge a_i \in A\}$. Ясно, что его дополнение \bar{A}_k будет включать все остальные элементы из A , т.е. $\bar{A}_k = \{a_i | a_i \notin I_k \wedge a_i \in A\}$. Тогда для любого интервала I_k имеем разбиение множества A на два класса эквивалентности A_k и \bar{A}_k , т.е. $A = A_k \cup \bar{A}_k, A_k \cap \bar{A}_k = \emptyset$.

Ранжирование λ_k , наведенное интервалом I_k , удовлетворяет следующим четырем условиям для $i, j = 1, \dots, n$: (1) $a_i \in A_k \wedge a_j \notin A_k \Rightarrow a_i \succ a_j$; (2) $a_i, a_j \in A_k \vee a_i, a_j \notin A_k \Rightarrow a_i \sim a_j$; (3) $a_i \notin A_k \wedge a_j \in A_k \Rightarrow a_j \succ a_i$; (4) $a_i, a_j \in A_k$ соседние элементы $\Rightarrow j \equiv i + 1$.

Заметим, что элементы класса A_k строго предпочтительнее, чем элементы класса \bar{A}_k , т.е. всегда $\lambda_k = A_k \succ \bar{A}_k$. Следовательно, каждое ранжирование λ_k содержит единственный символ строгого порядка \succ и $n - 2$ символов толерантности \sim .

Результат комплексирования x^* для полученного профиля Λ определяется следующим образом: определяются все возможные ранжирования консенсуса $\{\beta_1, \beta_2, \dots, \beta_N\}$ для профиля Λ по правилу Кемени рекурсивным алгоритмом ветвей и границ RECURSALL [12]; найденные ранжирования консенсуса преобразуются в единственное итоговое ранжирование консенсуса β_{fin} по правилу свёртки, описанному в [13]; в качестве результата комплексирования x^* принимаем наиболее предпочтительное дискретное значение в итоговом ранжировании консенсуса β_{fin} . Если β_{fin} содержит более одного наилучшего дискретного значения, то в качестве естественного представителя таких значений используется выборочная медиана, рассчитываемая для числа v наилучших элементов по известной формуле:

$$x^* = \begin{cases} a_{(v+1)/2}, & \text{если } v \text{ нечетно;} \\ (a_{v/2} + a_{1+v/2})/2, & \text{если } v \text{ четно.} \end{cases} \quad (1)$$

Гистограмма изображения. Для того, чтобы воспользоваться преимуществами метода IF&PA применительно к проблеме распознавания дефектов сварного шва, воспользуемся представлением анализируемого изображения с помощью гистограммы интенсивности, представляющей собой график распределения количества пикселей по уровням интенсивности (или уровням серого цвета) оцифрованного изображения [14] (рис. 2). Значения интенсивности (горизонтальная ось гистограммы) изменяются в диапазоне от 0 до 255 или при их нормировании путем деления на 255 — от 0 до 1. Значение 0 соответствует самому темному, т.е. чистому черному цвету, а максимальное значение интенсивности 255 (или 1 при нормировании) соответствует чистому белому цвету. Таким образом, чем больше пикселей изображения располагаются в области гистограммы, близкой к равной 0 интенсивности, тем темнее изображение; и чем больше пикселей изображения располагаются в области гистограммы, близкой к интенсивности, равной 255, тем светлее изображение. Часто на горизонтальной оси гистограммы выделяют пять зон одинаковой ширины l [14] (см. рис. 2) по степени интенсивности тона: черную, темную, среднюю, светлую и белую. Из рассмотрения большого количества разных изображений сварных швов следует, что большинство пикселей дефектной области принадлежат черной зоне гистограммы, а большинство пикселей бездефектной области принадлежат белой зоне гистограммы.

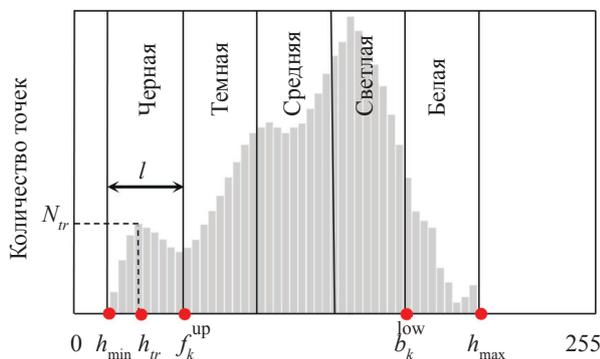


Рис. 2. Гистограмма изображения и ее зонирование.

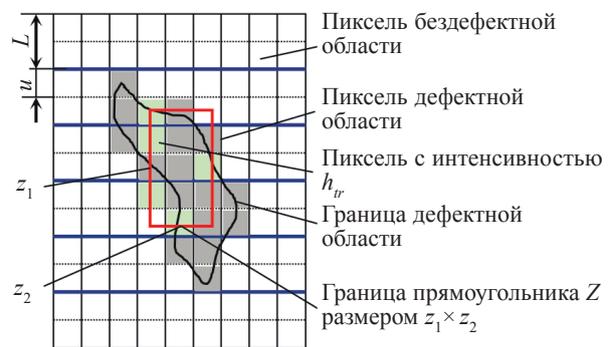


Рис. 3. Пример разбиения изображения S на горизонтальные полосы шириной L .

Для того, чтобы выявить информацию о начальных точках дефектной и бездефектной областей, исходное полутоновое изображение сварного соединения, представленное $(r \times q)$ матрицей S пикселей, необходимо разбить на несколько фрагментов, каждый из которых будет характеризоваться своим распределением интенсивности пикселей. Самой простой реализацией этой идеи является формирование из анализируемого изображения m горизонтальных (или вертикальных) *полос равной ширины* L (рис. 3), где $m = r / L$ (или $m = q / L$). Тогда по гисто-

граммам полос можно определить соответствующие интервалы $\{I_k\}$ яркости образующих их пикселей [15].

По гистограммам полос следует определять два набора по m интервалов — для переднего плана изображения (черной, т.е. дефектной, области) и для заднего плана (фона) изображения (белой, т.е. бездефектной, области). Тогда процедура IF&PA позволит вычислить робастные значения оценок интенсивностей переднего и заднего планов для каждого из двух наборов интервалов, которые служат порогами для выбора начальных точек в методе НО.

Рассмотрим теперь, как вычислить границы интервалов $\{I_k\}$, характеризующих гистограммы яркости этих полос, а также как выбрать подходящую ориентацию и число m полос разбиения изображения в зависимости от размера дефекта.

Определение границ исходных интервалов. Построим гистограмму интенсивности каждой полосы k полутонового изображения. Для каждой k -й гистограммы определяем два интервала: интервал $F_k = [f_k^{\text{low}}, f_k^{\text{up}}]$, представляющий дефектную область, и интервал $B_k = [b_k^{\text{low}}, b_k^{\text{up}}]$, представляющий бездефектную область. Для этого на k -й гистограмме формируем пять зон (как показано на рис. 2) шириной

$$l = 0,2(h_{\max} - h_{\min}), \quad (2)$$

где h_{\min} , h_{\max} — минимальная и максимальная интенсивности k -й полосы. Тогда границы интервалов F_k и B_k , представляющих соответственно дефектную и бездефектную области, определяются следующим образом:

$$f_k^{\text{low}} = h_{\min}; f_k^{\text{up}} = h_{\min} + l; b_k^{\text{low}} = h_{\max} - l; b_k^{\text{up}} = h_{\max}. \quad (3)$$

Выбор ориентации полос при разбиении изображения. Рассмотрим прямоугольник Z площадью $z_1 \times z_2$, где z_1 и z_2 — размер Z в пикселях по вертикали и горизонтали соответственно. Ориентация Z совпадает с ориентацией дефекта и большинство (больше половины) пикселей в Z принадлежат дефектной области (см. рис. 3). Ясно, что ориентация полос всегда перпендикулярна ориентации прямоугольника Z .

Пусть h_r — это интенсивность, которую имеет наибольшее количество N_r пикселей в *черной области гистограммы* (см. рис. 3). Выберем не менее трех максимально удаленных друг от друга на изображении пикселей, имеющих интенсивность h_r . Прямые вертикальные и горизонтальные линии, проходящие через эти пиксели, определяют ограничивающий дефектную область прямоугольник Z , соотношение размеров которого определяет ориентацию полос: если $z_1 > z_2$, то ориентация полос горизонтальная, если $z_1 \leq z_2$, то ориентация вертикальная.

Выбор количества m полос. Пусть m_1 — это количество полос, содержащих пиксели дефектной области; m_2 — количество полос, содержащих пиксели только бездефектной области. Ясно, что $m_1 + m_2 = m$. Достаточно определить значение m , при котором выполняется условие $m_1 \geq m_2$ для случая горизонтальной ориентации полос ($z_1 > z_2$).

Пусть $z'_1 = r - z_1$ и $z'_2 = q - z_2$ — это параметры дополнения Z' ограничивающего прямоугольника Z до всего изображения C размером $(r \times q)$ пикселей, т.е. $Z' = C \setminus Z$.

Если $z_1 \geq z'_1$ (т.е. размер дефекта сравним с размером изображения C), то $m_1 \geq m_2$ для всех m . В статье [16] с помощью моделирования по схеме последовательных испытаний Бернулли показано, что в такой ситуации можно брать значения m равными от 4 до 15. Это означает что, при $m > 15$ точность сегментации практически не увеличивается.

Если $z_1 < z'_1$ (т.е. размер дефекта мал по сравнению с размером изображения C), то, чтобы выполнялось условие $m_1 \geq m_2$, следует подобрать некоторое натуральное число $u < L$, обеспечивающее выполнение равенств $m_1 = (z_1 + u)/L$ и $m_2 = (z'_1 - u)/L$. Например, для изображения на рис. 3 имеем следующие значения параметров: $r = 12$; $q = 9$; $z_1 = 5$; $z_2 = 3$. Поскольку $z_1 > z_2$, то ориентация полос горизонтальная. Ясно, что $z'_1 = 12 - 5 = 7$ и $z_1 < z'_1$. Выбираем $u = 1$, откуда $m_1 = m_2$. Тогда выбираем $L = 2$, обеспечивая максимальное значение $m = 12/2 = 6$.

МЕТОД НАРАЩИВАНИЯ ОБЛАСТЕЙ

Начальные точки после определения с помощью IF&PA маркируются одной из двух областей — дефектной E или бездефектной P . Затем наборы этих точек расширяются путем их объединения с точками, которые имеют близкую интенсивность и не маркированы. Нарастивание области происходит последовательно с учетом текущего значения ее дисперсии интенсивности.

Предположим, что дефектная область E включает в себя пиксели x_i с интенсивностью h_i . Среднее значение H_E и дисперсия интенсивности V_E для дефектной области E в целом рассчитываются следующим образом:

$$H_E = (1/|E|) \sum_{i=1}^{|E|} h_i, \quad (4)$$

$$V_E = (1/(|E|-1)) \sum_{i=1}^{|E|} (h_i - H_E)^2, \quad (5)$$

где $|E|$ — размер (число точек) области E .

Пусть дефектная область E имеет набор соседей S_E , определяемых с использованием известного понятия восьмисвязности, когда пиксели считаются соседними, если их координаты по вертикали, горизонтали и диагонали отличаются не более чем на единицу [14]. Тогда точки x считаются соседями области E , если $x \in S_E$ и $x \notin E$.

Предположим, что точка $x \in S_E$ включена в область E , тогда среднее значение и дисперсия интенсивности области E изменятся в зависимости от значения интенсивности точки x . Обозначим через $V_E(x)$ дисперсию интенсивности точки $x \in S_E$. Определим точку $x_{V_E \min} \in S_E$ с минимальной дисперсией $V_{E \min}$ для области E следующим образом:

$$x_{V_E \min} = \arg \min_{x \in S_E} V_E(x); \quad V_{E \min} = \min \{V_E(x) | x \in S_E\}. \quad (6)$$

Аналогичным образом определяется точка $x_{V_P \min} \in S_P$ с минимальной дисперсией $V_{P \min}$ для бездефектной области P .

Дисперсия интенсивности области показывает отклонение интенсивностей ее пикселей и по отношению к интенсивности центрального пикселя (принятой за среднее значение) области. Невысокое значение дисперсии показывает, что интенсивность точек незначительно отличается от среднего значения интенсивности области или что точки области имеют практически одинаковую интенсивность. И наоборот, чем больше дисперсия, тем больше разница интенсивностей точек области. Заметим, что дефектная E и бездефектная P области порождаются начальными точками с одинаковой интенсивностью, т.е. метод НО начинает работу при нулевых дисперсиях областей E и P .

Таким образом, в основу метода НО можно положить следующий принцип: в область включается та точка, которая изменяет ее дисперсию в наименьшей степени, т.е. если $V_{E \min} \leq V_{P \min}$, то пиксель $x_{V_E \min}$ включается в область E , иначе пиксель $x_{V_P \min}$ включается в область P . Этот процесс продолжается, пока не будут исчерпаны все точки, т.е. выполнится равенство $|E| + |P| = |C|$.

АЛГОРИТМ АВТОМАТИЧЕСКОГО РАСПОЗНАВАНИЯ ДЕФЕКТОВ СВАРКИ

Описанные выше предложения по созданию системы автоматического распознавания дефектов сварных соединений (АРДС) были реализованы авторами в среде технических вычислений Matlab 2020b. Система АРДС является дальнейшим развитием системы АД, описанной в предыдущей статье авторов [2]. Опишем последовательность действий алгоритма АРДС на примере обнаружения дефекта «прожог» (подгруппа 510 стандарта ГОСТ Р ИСО 6520 [7]) по фотографическому изображению сварного шва (см. рис. 4). Это как раз тот вид дефекта, при распознавании которого предыдущая версия системы в подавляющем большинстве экспериментов вынуждена была использовать интерактивный (ручной) режим [2].

1. На вход алгоритма подается цветное изображение сварного шва в формате RGB размером (180×240) пикселей (рис. 4а), которое преобразуется в полутоновое изображение B с помощью функции *rgb2gray*; для подавления яркостных помех с помощью функции *imgaussfilt* (фильтр Гаусса при стандартном отклонении $\sigma = 2$) изображение B преобразуется в полутоновое изображение C с низким уровнем шума (рис. 4б).

2. Пользуясь рекомендациями раздела «Комплексообразование интервалов агрегированием предпочтений», выбираем число полос $m = 10$ и горизонтальную ориентацию полос; с помощью функции *imcrop* формируем 10 полутоновых изображений C_1, C_2, \dots, C_{10} одинаковой высоты $L = 24$ (рис. 5).

3. Строим гистограмму каждой полосы C_k , $k = 1, 2, \dots, 10$, с помощью функции *imhist* (см. рис. 5).

4. Для каждой гистограммы C_k по формулам (2) и (3) определяем два интервала: интервал $F_k = [f_k^{\text{low}}, f_k^{\text{up}}]$, представляющий дефектную область, и интервал $B_k = [b_k^{\text{low}}, b_k^{\text{up}}]$, представляющий

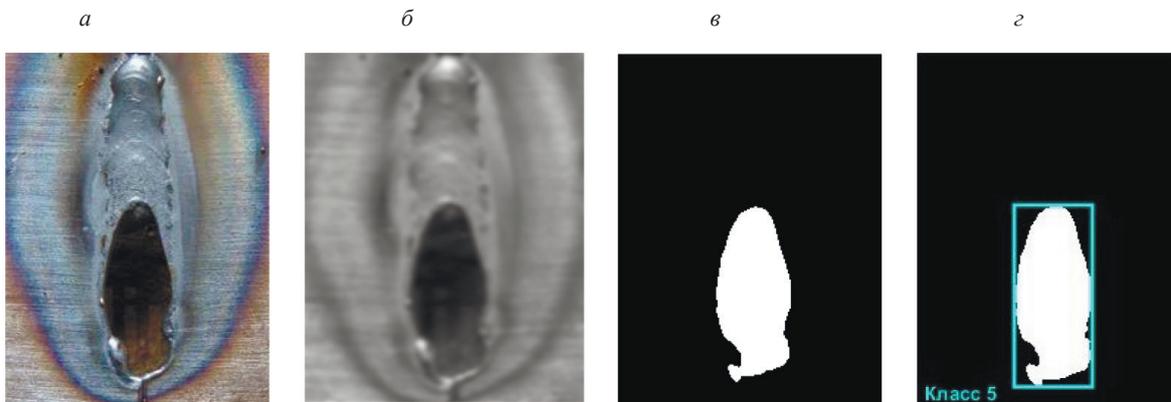


Рис. 4. Сегментация дефекта типа «прожог»: *a* — исходное изображение; *б* — отфильтрованное изображение *C*; *в* — результат работы алгоритма НО с начальными точками, выбранными с помощью IF&PA; *г* — результат классификации дефекта.

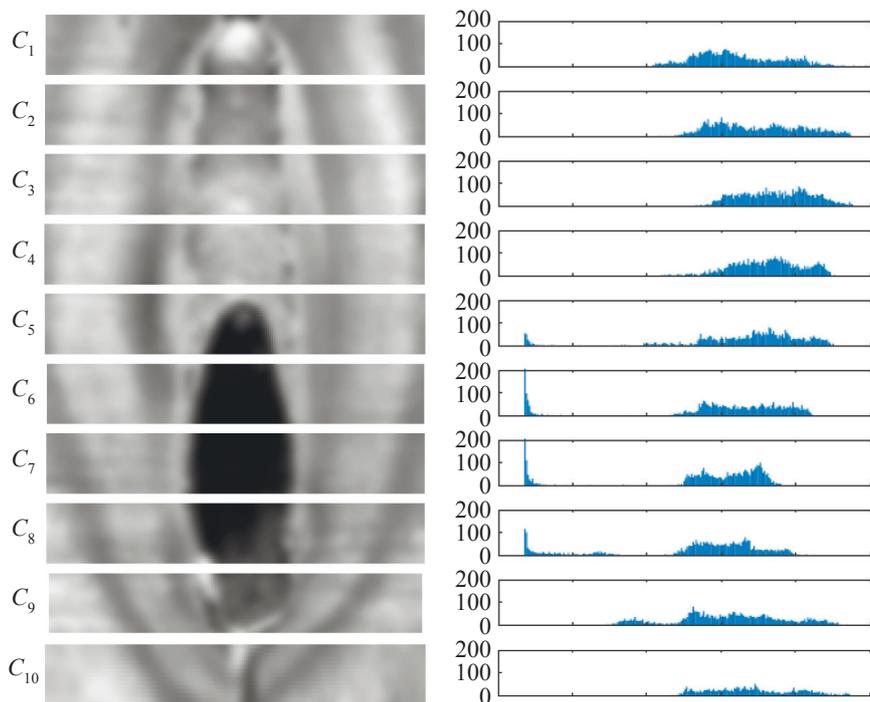


Рис. 5. Разбиение изображения *C* на 10 горизонтальных полос C_1, C_2, \dots, C_{10} и их гистограммы.

бездефектную область. Значения границ соответствующих интервалов для рассматриваемого примера представлены в табл. 1.

7. Набор интервалов $F_k, k = 1, 2, \dots, 10$, для дефектной области подаем на вход процедуры IF&PA, которая формирует диапазон актуальных значений $A = \{a_1, a_2, \dots, a_{10}\}$, как показано на рис. 6. Нижняя граница ДАЗ $a_1 = 18$, верхняя граница $a_{10} = 150$, норма $h = 150 - 18 / 9 \approx 14,67$. Полученные десять дискретных значений интенсивности a_1, a_2, \dots, a_{10} показаны на левой вертикальной оси на рис. 6. Соответствующие интервалам ранжирования, представленные в короткой форме, формируют профиль предпочтения, показанный в правой части рис. 6.

На выходе процедуры IF&PA после свертки 48 ранжирований Кемени, найденных алгоритмом RECURSALL, получаем итоговое ранжирование консенсуса $\beta_{fin}: a_2 \sim a_3 \succ a_1 \sim a_7 \succ a_6 \sim a_8 \succ a_4 \sim a_9 \sim a_{10} \succ a_5$.

Поскольку итоговое ранжирование содержит две наилучшие альтернативы $a_2 \sim a_3$, т.е. $v = 2$, по формуле (1) получаем $x^* = (a_2 + a_3) / 2 = (32,67 + 47,33) / 2 = 40,0$. Найденный результат комплек-

Границы интервалов F_k и B_k , представляющих дефектную и бездефектную области

Полоса C_k	Интервал F_k		Интервал B_k	
	f_k^{low}	f_k^{up}	b_k^{low}	b_k^{up}
C_1	82	115	216	249
C_2	97	125	209	237
C_3	128	150	217	239
C_4	97	123	201	227
C_5	18	60	185	227
C_6	18	57	173	212
C_7	18	53	158	193
C_8	18	59	182	223
C_9	69	103	205	239
C_{10}	85	116	207	238

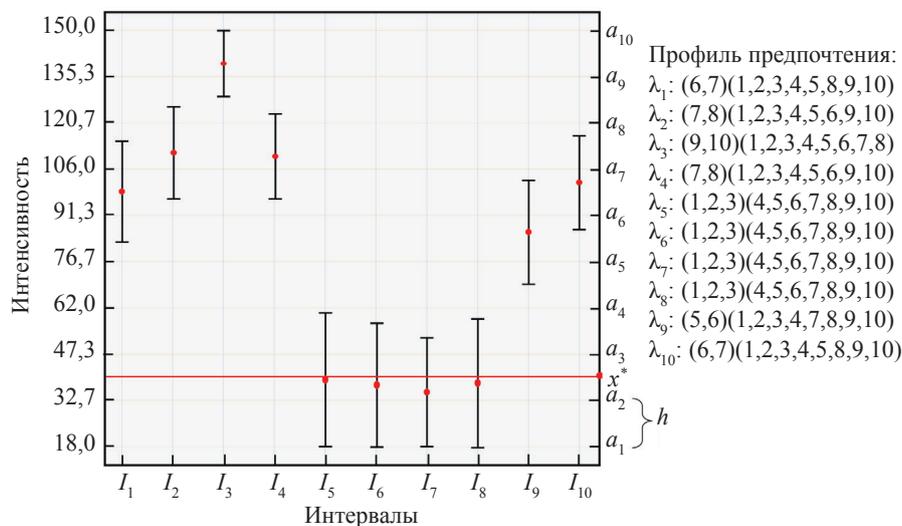


Рис. 6. Работа процедуры IF&PA с входными данными дефектной области.

сирования принимается за значение интенсивности начальной точки дефектной области $f = x^* = 40$ при последующем применении метода НО.

8. Набор интервалов B_k , $k = 1, 2, \dots, 10$, для бездефектной области подаем на вход процедуры IF&PA, которая формирует новый диапазон актуальных значений $A = \{a_1, a_2, \dots, a_{10}\}$, как показано на рис. 7. В этом случае нижняя граница ДАЗ $a_1 = 158$, верхняя граница $a_{10} = 249$, норма $h \approx 10,11$.

Были получены 12 ранжирований Кемени, которые после свертки дали следующее итоговое ранжирование консенсуса $\beta_{\text{fin}}: a_7 \succ a_6 \succ a_8 \succ a_4 \succ a_5 \succ a_9 \succ a_3 \succ a_2 \succ a_1 \succ a_{10}$, откуда получаем $x^* = a_7 = 218,67$. Найденный результат комплексирования принимается за значение интенсивности начальной точки бездефектной области $b = x^* = 219$ при последующем применении метода НО.

9. Запускаем реализующую метод НО функцию $D = \text{regionGrowing}(C, f, b)$, где D — изображение после сегментации, C — изображение, полученное на шаге 1, f и b — значения интенсивности, представляющие дефектную и бездефектную области, полученные на шагах 7 и 8 соответственно. Результатом является бинаризованное изображение D (см. рис. 4в), где белым цветом представлена область дефекта сварного шва (если он существует).

10. Определение одного из шести классов (1 — отсутствие дефекта; 2 — полость; 3 — продольная трещина; 4 — поперечная трещина; 5 — прожог; 6 — два и более дефектов классов 2—5) дефекта $Class$ по значениям геометрических признаков дефектной области сварного шва

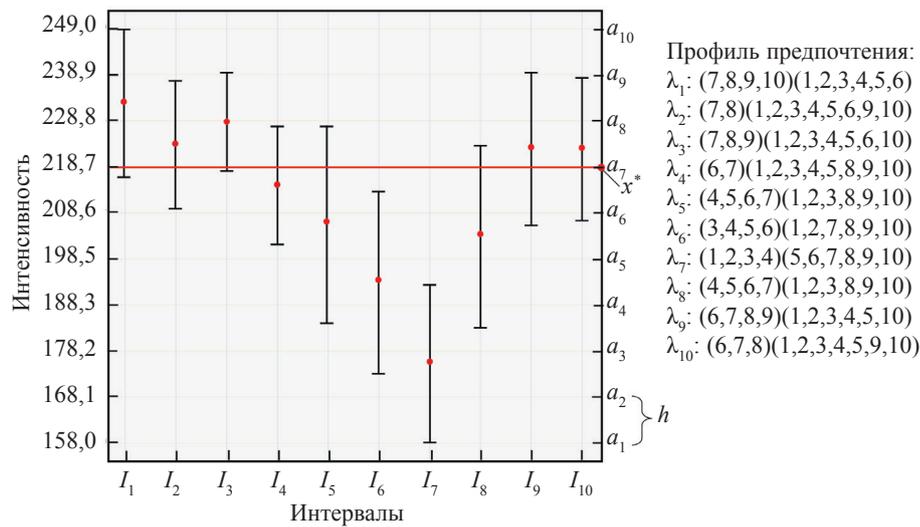


Рис. 7. Работа процедуры IF&PA с входными данными бездефектной области.

на изображении D , таким как длина, ширина, коэффициент заполнения, коэффициент округлости, коэффициент прямоугольности и т.д., как описано в статье авторов [2] (см. рис. 4г).

ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ

Предложенный алгоритм АРДС был протестирован на наборе из 87 различных изображений сварных швов с дефектами всех шести определяемых на шаге 10 алгоритма классов, полученных в свободном доступе из сети Интернет. Для сравнения те же изображения предъявлялись реализованным в среде Matlab традиционным популярным методам распознавания: методу Оцу [17, 18] (определяет оптимальный порог для различения дефектной и бездефектной областей по минимальной дисперсии) и методу k -средних [19] (пиксели изображения классифицируются на k групп данных в соответствии с характеристиками интенсивности цвета).

Результаты распознавания, полученные в интерактивном (ручном) режиме АРДС, были использованы в ходе экспериментальных исследований как заведомо правильные (истинные) для оценки качества распознавания исследуемыми тремя методами с использованием меры сходства Жаккара J [20], известной также как *intersection over union* (IoU) [21]. Мера определяется как отношение мощности пересечения множеств A и B к мощности их объединения, где A — область дефекта, распознанного одним из трех методов, а B — область реального дефекта, полученного в ручном режиме. Формула для расчета меры Жаккара имеет вид:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|}. \quad (7)$$

Значение меры J находится в диапазоне $[0, 1]$. Если $J = 0$, то объекты A и B не пересекаются, т.е. дефект A не распознан; если $J = 1$, то A и B полностью совпадают, т.е. дефект A полностью распознан.

Результаты испытаний, приведенные в табл. 2, показывают, что из 87 протестированных изображений 83 изображения были распознаны правильно предложенным алгоритмом АРДС. Это значит, что для этого конкретного набора протестированных изображений точность АРДС достигает 95,4 % и превышает точность традиционных методов Оцу (57,4 %) и k -средних (71,3 %). В табл. 2 приведена также точность каждого исследуемого метода по отдельным классам дефектов. Используемый здесь показатель «точность» (ассигасу) является одной из распространенных, простейшей и интуитивно понятной оценкой качества распознавания, рассчитываемой как выраженная в процентах доля правильно распознанных дефектов среди всех предъявленных объектов.

Для каждого результата распознавания исследуемых дефектов были рассчитаны значения меры Жаккара, которые в усредненном виде по каждому классу дефектов и используемому методу приведены в табл. 3. Конкретные примеры исследуемых изображений дефектов и результаты их распознавания с соответствующими значениями меры J даны на рис. 8.

Количество автоматически распознанных дефектов

Класс. Наименование дефекта	Предъявлено	Распознано методом			Точность метода, %		
		Оцу	<i>k</i> -средних	АРДС	Оцу	<i>k</i> -средних	АРДС
1. Отсутствие дефекта	10	10	10	10	100	100	100
2. Полость	14	9	11	13	64,3	78,6	92,9
3. Продольная трещина	21	8	13	20	38,1	61,9	95,2
4. Поперечная трещина	14	10	10	14	71,4	71,4	100
5. Прожог	13	7	10	12	53,8	76,9	92,3
6. Два и более дефектов классов 2 – 5	15	6	8	14	40,0	53,3	93,3
Всего	87	50	62	83	57,4	71,3	95,4

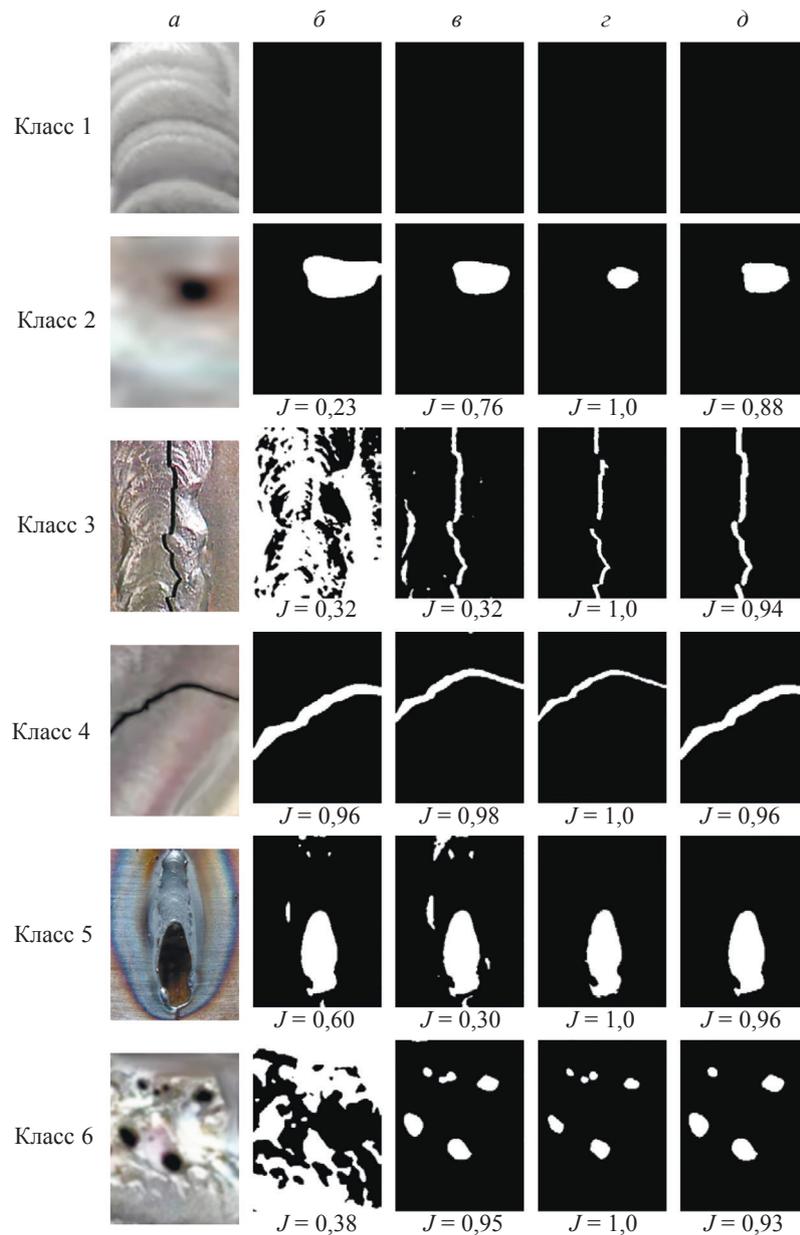


Рис. 8. Примеры результатов распознавания различных классов дефектов сварных швов: *a* — исходное изображение; *б* — метод Оцу; *в* — метод *k*-средних; *г* — алгоритм АРДС (ручной режим); *д* — алгоритм АРДС (автоматический режим).

Таблица 3

Усредненные значения меры J при распознавании разных классов дефектов

Класс. Наименование дефекта	Метод Оцу	Метод k -средних	АРДС
1. Отсутствие дефекта	–	–	–
2. Полость	0,59	0,71	0,78
3. Продольная трещина	0,49	0,64	0,83
4. Поперечная трещина	0,71	0,69	0,88
5. Прожог	0,53	0,67	0,87
6. Два и более дефектов классов 2—5	0,47	0,64	0,76

Из данных табл. 2, 3 и рис. 8 следует, что предложенный алгоритм АРДС имеет преимущества перед традиционными методами при автоматическом обнаружении дефектов сварных швов на всех классах дефектов. Особенно явными эти преимущества являются в тех случаях, когда дефект представляет собой продольную трещину или распространяется вдоль изображения, или имеет относительно большую площадь по сравнению с анализируемым изображением. Результаты экспериментов также показывают, что АРДС эффективно устраняет мешающие правильному распознаванию элементы на изображении.

Из экспериментальных данных также следует, что выигрыш от применения алгоритма АРДС несколько снижается в следующих случаях: площадь дефекта слишком мала по сравнению с размерами анализируемого изображения; изображение имеет темные бездефектные участки; разница между интенсивностями цвета дефектных и бездефектных участков невелика. Преодоление этих трудностей составляет предмет дальнейших исследований по совершенствованию предложенного подхода.

ЗАКЛЮЧЕНИЕ

В данной статье предложен метод АРДС для автоматической сегментации изображений при обнаружении дефектов поверхности сварного шва, основанный на методе последовательного наращивания дефектной и бездефектной областей, начальные пороговые значения интенсивности пикселей которых автоматически определяются методом комплексирования интервалов агрегированием предпочтений.

Результаты экспериментальных исследований 87 изображений сварных соединений показали, что предложенный алгоритм корректно распознал 83 дефекта, т.е. характеризуется точностью 95,4 %, которая превысила точность таких известных методов распознавания, как метод Оцу и метод k -средних.

Заметим, что АРДС не предназначен для распознавания изображений, на которых присутствуют края свариваемых деталей (не обязательно прямолинейные), значительные перепады высоты (выступы или впадины), неметаллические вставки и т.д. Эти изображения не содержат дефекты, но за таковые могут быть приняты изменения интенсивности пикселей, которые появляются на изображении из-за перепадов рельефа объекта контроля [22]. Решение подобных проблем — предмет дальнейших исследований по теме.

СПИСОК ЛИТЕРАТУРЫ

1. *Nacereidine N., Goumeidane A.B., Ziou D.* Unsupervised weld defect classification in radiographic images using multivariate generalized Gaussian mixture model with exact computation of mean and shape parameters // *Computers in Industry*. 2019. V. 108. P. 132—149.
2. *Муравьев С.В., Погадаева Е.Ю.* Автоматизированное распознавание дефектов сварных соединений при визуальном контроле с использованием геометрических признаков // *Дефектоскопия*. 2020. № 3. С. 49—57.
3. *Mery D., Pieringer C.* *Computer Vision for X-Ray Testing: Imaging, Systems, Image Databases, and Algorithms*. Springer. 2021. 456 p. ISBN 978-3-030-56768-2.
4. *Zhang L., Zhang Y., Dai B., Chen B., Li Y.* Welding defect detection based on local image enhancement // *IET Image Processing*. 2019. V. 13. P. 2647—2658.
5. *Yazid H., Arof H., Yazid H.* Automated thresholding in radiographic image for welded joints // *Nondestructive Testing and Evaluation*. 2012. V. 27. No. 1. P. 69—80.

6. Zahran O., Kasban H., El-Kordy M., Abd El-Samie F.E. Automatic weld defect identification from radiographic images // *NDT & E International*. 2013. V. 57. P. 26—35.
7. ГОСТ Р ИСО 6520—1—2012. Сварка и родственные процессы. Классификация дефектов геометрии и сплошности в металлических материалах. Часть 1. Сварка плавлением.
8. Mancas M., Gosselin B., Macq B. Segmentation using a region-growing thresholding // *Proceedings of SPIE. Image Processing: Algorithms and Systems IV*. 2005. V. 5672. P. 388—398.
9. Sheela C.J.J., Suganthi G. Morphological edge detection and brain tumor segmentation in Magnetic Resonance (MR) images based on region growing and performance evaluation of modified Fuzzy C-Means (FCM) algorithm // *Multimedia Tools and Applications*. 2020. V. 79. P. 17483—17496.
10. Muravyov S.V., Khudonogova L.I., Emelyanova E.Y. Interval data fusion with preference aggregation // *Measurement*. 2018. V. 116. P. 621—630.
11. Muravyov S.V., Khudonogova L.I., Ho M.D. Analysis of heteroscedastic measurement data by the self-refining method of interval fusion with preference aggregation — IF&PA // *Measurement*. 2021. V. 183. P. 109851.
12. Muravyov S.V. Ordinal measurement, preference aggregation and interlaboratory comparisons // *Measurement*. 2013. V. 46. No. 8. P. 2927—2935.
13. Muravyov S.V., Emelyanova E.Y. Kemeny rule for preference aggregation: reducing all exact solutions to a single one // *Measurement*. 2021. V. 182. P. 109403.
14. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2012. 1104 с.
15. 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», Dubrovnik, Croatia. October 19—22. 2020. P. 271—276.
16. Муравьев С.В., Маринушкина И.А. Обоснование выбора числа участников межлабораторных сличений // *Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика. Телекоммуникации. Управление*. № 4. 2015. С. 81—90.
17. Otsu N. A Threshold Selection Method from Gray-Level Histograms // *IEEE Transactions on Systems, Man, and Cybernetics*. 1979. V. 9. No. 1. P. 62—66.
18. Zhan Y., Zhang G. An improved OTSU algorithm using histogram accumulation moment for ore segmentation // *Symmetry*. 2019. V. 11. No. 3. P. 431.
19. Dhanachandra N., Manglem K., Chanu Y.J. Image segmentation using K-means clustering algorithm and subtractive clustering algorithm // *Procedia Computer Science*. 2015. V. 54. P. 764—771.
20. Levandowsky M., Winter D. Distance between Sets // *Nature*. 1971. V. 234. P. 34—35.
21. Zhou D., Fang J., Song X., Guan C., Yin J., Dai Y., Yang R. IoU loss for 2D/3D object detection / *Proceedings of the 7th International Conference on 3D Vision*. Québec City, Canada, September 16—19, 2019. V. 1. P. 85—94.
22. Dedkova A.A., Florinsky I.V. Geomorphometry and microelectronic metrology: Converged realms // *Transactions in GIS*. 2023. V. 27. No. 6. P. 1642—1661.